

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky
a komunikačních technologií

BAKALÁRSKA PRÁCA

Brno, 2019

MARTINA BJELOVÁ



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

**DETEKCIA K-KOMPLEXOV ZO SPÁNKOVÝCH
ZÁZNAMOV EEG**

K-COMPLEX DETECTION IN SLEEP EEG

BAKALÁRSKA PRÁCA

BACHELOR'S THESIS

AUTOR PRÁCE

AUTHOR

Martina Bjelová

VEDÚCI PRÁCE

ADVISOR

Ing. Martin Králík

BRNO 2019

Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

Studentka: Martina Bjelová

ID: 186652

Ročník: 3

Akademický rok: 2018/19

NÁZEV TÉMATU:

Detekce K-komplexů ze spánkových záznamů EEG

POKYNY PRO VYPRACOVÁNÍ:

1) Nastudujte problematiku polysomnografie a snímání spánkového EEG. 2) Seznamte se s problematikou grafoelementů u spánkových záznamů a možnostmi detekce K-komplexů, poznatky shrňte v literární rešerši. 3) Vyberte jednu metodu detekce K-komplexů a realizujte ji na úsecích EEG signálu. 4) Realizujte alespoň jednu další metodu, srovnajte úspěšnost detekce na volně dostupné databázi. 5) Dosažené výsledky vhodně shrňte a srovnajte s jinými autory.

DOPORUČENÁ LITERATURA:

[1]KROHNE, Laerke K., Rie B. HANSEN, Julie A. E. CHRISTENSEN, Helge B. D. SORENSEN a Poul JENNUM, 2014. Detection of K-complexes based on the wavelet transform. In: 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE, 2014, s. 5450-5453

[2]DEVUYST, S, T DUTOIT, P STENUIT a M KERKHOFS, 2010. Automatic K-complexes detection in sleep EEG recordings using likelihood thresholds. In: 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology. IEEE, 2010, s. 4658-4661

Termín zadání: 4.2.2019

Termín odevzdání: 24.5.2019

Vedoucí práce: Ing. Martin Králík

Konzultant:

prof. Ing. Ivo Provazník, Ph.D.
předseda oborové rady

UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

ABSTRAKT

Táto práca sa zaoberá detekciou K-komplexov v spánkových EEG záznamoch. Polysomnografia je metóda, ktorá je využívaná pre diagnostiku a následnú liečbu mnohých porúch spánku. Pre určenie spánkových štádií je podstatné poznať grafoelementy, ktoré sa v nich vyskytujú. K-komplex je dôležitým ukazovateľom druhého štádia spánku a preto je podstatné vedieť tento vzor detegovať. V práci sa zameriavame na návrh a realizáciu viacerých algoritmov pre detekciu týchto vzorov s rozmanitými vlastnosťami. Spomedzi navrhnutých metód bola najlepšie vyhodnotená metóda s využitím vlnkovej transformácie. Výkon tejto detekcie dosiahol priemernú senzitivitu 63,83 % a priemernú pozitívnu prediktívnu hodnotu 44,07 %.

KLÚČOVÉ SLOVÁ

Elektroencefalografia (EEG), polysomnografia (PSG), spánkové štádiá, K-komplex, fuzzy hodnoty, TKEO, vlnková transformácia, MATLAB

ABSTRACT

This paper addresses detecting of K-complexes in sleeping EEG records. Polysomnography is the method, which is used for diagnostic and following therapy of many sleep disorders. For identifying of sleep stages it is fundamental to know graphoelements, in which they are situate. K-complex is important indicator of second sleep stange and hence is essencial to know to detect this pattern. In this paper we focus on design and implementation of more algorithms for detection of these patterns with various characteristics. Among the proposed methods, the wavelet transform method was best evaluated. Performance of this detection reached values the average senzitivity 63,83 % and average positive predictive value 44,07 %.

KEYWORDS

Electroencephalography (EEG), polysomnography (PSG), sleeping stages, K-complex, fuzzy values, TKEO, wavelet transformation, MATLAB

BJELOVÁ, Martina. *Detekcia K-komplexov zo spánkových záznamov EEG*. Brno, 2019, 60 s. Bakalárska práca. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedúci práce: Ing. Martin Králík

VYHLÁSENIE

Vyhlasujem, že som svoju bakalársku prácu na tému „Detekcia K-komplexov zo spánkových záznamov EEG“ vypracovala samostatne pod vedením vedúceho bakalárskej práce, využitím odbornej literatúry a ďalších informačných zdrojov, ktoré sú všetky citované v práci a uvedené v zozname literatúry na konci práce.

Ako autorka uvedenej bakalárskej práce ďalej vyhlasujem, že v súvislosti s vytvorením tejto bakalárskej práce som neporušila autorské práva tretích osôb, najmä som nezasiahla nedovoleným spôsobom do cudzích autorských práv osobnostných a/alebo majetkových a som si plne vedomá následkov porušenia ustanovenia § 11 a nasledujúcich autorského zákona Českej republiky č. 121/2000 Sb., o práve autorskom, o právach súvisiacich s právom autorským a o zmene niektorých zákonov (autorský zákon), v znení neskorších predpisov, vrátane možných trestnoprávných dôsledkov vyplývajúcich z ustanovenia časti druhej, hlavy VI. diel 4 Trestného zákoníka Českej republiky č. 40/2009 Sb.

Brno

.....

podpis autorky

POĎAKOVANIE

Rada by som poďakovala vedúcemu bakalárskej práce pánovi Ing. Martinovi Králíkovi za odborné vedenie, konzultácie, trpezlivosť a podnetné návrhy k práci.

Brno

.....

podpis autorky

Obsah

Úvod	10
1 Elektroencefalografia	11
1.1 Snímanie EEG signálov	12
1.2 EEG v polysomnografii	13
1.3 Spracovanie spánkových EEG signálov	17
1.3.1 Artefakty	19
1.3.2 Grafoelementy	20
1.3.3 Metódy spracovania spánkových EEG	21
2 Možnosti detekcie K-komplexov	24
2.1 Metóda s výpočtom vlnkovej transformácie	24
2.2 Metóda pracujúca s fuzzy prahovými hodnotami	25
2.3 Metóda s využitím Teager-Kaiser energetického operátora	25
2.4 Štatistické vyhodnocovanie účinnosti detektorov	26
3 Návrh a realizácia detekcie K-komplexov	28
3.1 Detekcia K-komplexov s využitím fuzzy prahových hodnôt (FIR) . . .	28
3.1.1 Predspracovanie a extrakcia príznakov	29
3.1.2 Výpočet príznakov	30
3.1.3 Výstup detekcie	32
3.1.4 Účinnosť realizovanej metódy	33
3.2 Detekcia K-komplexov s využitím fuzzy prahových hodnôt (IIR) . . .	34
3.2.1 Predspracovanie	34
3.2.2 Extrakcia a prijatie príznakov	35
3.2.3 Výstup detekcie	36
3.2.4 Účinnosť realizovanej metódy	37
3.3 Detekcia K-komplexov s využitím Teager-Kaiser energetického operá- tora	38
3.3.1 Predspracovanie	38
3.3.2 Extrakcia a odstraňovanie príznakov	39
3.3.3 Výstup detekcie	40
3.3.4 Účinnosť realizovanej metódy	41
3.4 Detekcia K-komplexov s využitím vlnkovej transformácie	43
3.4.1 Predspracovanie	43
3.4.2 Extrakcia a odstraňovanie príznakov	44
3.4.3 Výstup detekcie	45

3.4.4	Účinnosť realizovanej metódy	46
3.5	Detekcia K-komplexov s využitím dekompozície pomocou vlnkovej transformácie	47
3.5.1	Predspracovanie	48
3.5.2	Extrakcia a odstraňovanie príznakov	48
3.5.3	Výstup detekcie	49
3.5.4	Účinnosť realizovanej metódy	50
3.6	Štatistické porovnanie účinnosti algoritmov	51
4	Záver	54
	Literatúra	56
	Zoznam symbolov, veličín a skratiek	58
	Zoznam príloh	59
A	Obsah priloženého CD	60

Zoznam obrázkov

1.1	Rozmiestnenie EEG elektród na hlave	12
1.2	Ukážka zapojenia snímačov a elektród pri PSG vyšetrení - upravené z [3]	14
1.3	Frekvenčné rozdelenie rytmov v EEG signále - upravené z [5]	16
1.4	Ukážka niektorých grafoelementov v surovom EEG signále	21
3.1	Bloková schéma navrhnutého algoritmu pre detekciu K-komplexov .	28
3.2	Porovnanie signálu pred a po FIR filtrácii	29
3.3	Ukážka príznakov na reálnom K-komplexe	30
3.4	Ukážka výslednej detekcie príznakov K-komplexov	32
3.5	Ukážka navrhnutej detekcie K-komplexov v porovnaní s expertom . .	32
3.6	Bloková schéma navrhnutého algoritmu pre detekciu K-komplexov .	34
3.7	Porovnanie signálu pred a po IIR filtrácii	35
3.8	Významné body K-komplexu	36
3.9	Ukážka navrhnutej detekcie K-komplexov v porovnaní s expertom . .	37
3.10	Bloková schéma navrhnutého algoritmu pre detekciu K-komplexov .	39
3.11	Porovnanie signálu pred a po filtrácii	39
3.12	Energia signálu získaná aplikáciou TKEO	40
3.13	Ukážka vyhľadávaných príznakov	41
3.14	Ukážka nájdených K-komplexov v porovnaní s expertom	41
3.15	Bloková schéma navrhnutého algoritmu	43
3.16	Porovnanie signálu pred a po predspracovaní	44
3.17	Ukážka hľadaných bodov	45
3.18	Ukážka nájdených K-komplexov v porovnaní s expertom	46
3.19	Bloková schéma navrhnutého algoritmu	47
3.20	Porovnanie signálu pred a po predspracovaní	48
3.21	Ukážka hľadaných bodov	49
3.22	Ukážka nájdených K-komplexov v porovnaní s expertom	49

Zoznam tabuliek

1.1	Popis použitých znakov v obrázku 1.1	11
1.2	Prehľad spánových fáz [1], [4]	15
1.3	Frekvenčné rozdelenie rytmov v EEG signále - zhrnutie	17
3.1	Množstvo nájdených K-komplexov v signáloch databázy	33
3.2	Prehľad štatistických hodnôt pre porovnanie s referenciami	33
3.3	Množstvo nájdených K-komplexov v signáloch databázy	37
3.4	Prehľad štatistických hodnôt pre porovnanie s referenciami	38
3.5	Množstvo nájdených K-komplexov v signáloch databázy	42
3.6	Prehľad štatistických hodnôt pre porovnanie s referenciami	42
3.7	Množstvo nájdených K-komplexov v signáloch databázy	46
3.8	Prehľad štatistických hodnôt pre porovnanie s referenciami	47
3.9	Množstvo nájdených K-komplexov v signáloch databázy	50
3.10	Prehľad štatistických hodnôt pre porovnanie s referenciami	50
3.11	Priemerné hodnoty štatistických parametrov	51
3.12	Priemerná senzitivita metód vychádzajúca z rovnakého článku [11] .	52
3.13	Priemerná senzitivita metód vychádzajúca z rovnakého článku [14] .	52
3.14	Porovnanie metódy z článku [11] proti nami realizovaným metódam .	53

Úvod

Spánkové štúdie sa zaoberajú nie len poruchami spánku a bdenia, ale aj ich samotnou diagnostikou a liečbou. Vykonávané sú pomocou polysomnografu, ktorý znamená väčšinu dôležitých fyziologických prejavov. Medzi najzákladnejšie diagnostické prístroje pri týchto štúdiách patrí spánková elektroencefalografia. Touto metódou sú získané dôležité informácie o elektrických pochodoch v mozgu človeka. Z nameraných dát je potom možné získať hypnogram, ktorý tvorí komplexný pohľad na striedanie spánkových fáz počas celého nahrávania. Základným hodnotiacim prvkom je však samotný EEG signál. Po jeho spracovaní získavame znalosť v zastúpení rôznych komponentov, ktoré sú podľa povahy mnohokrát dôležitými diagnostickými ukazovateľmi v oblasti spánku. Okrem iného sa medzi špecificky objavujúce sa vzory radia grafoelementy nazývané K-komplexy.

Táto práca sa zameriava na detekciu K-komplexov v spánkových EEG. Jednotlivé časti teoretického úvodu sa sústreďujú na vysvetlenie polysomnografického nahrávania, ďalej sme prešli k problematike nahrávania a samotnému významu EEG signálu, rozobrali možnosti jeho spracovania a objasnili dôležité rozdiely medzi artefaktmi a grafoelementami, ktoré vznikajú pri snímaní. Neskôr sme sa špecifikovali už len na samotné K-komplexy a možnosti ich detekcie. Prihliadali sme tiež na niektoré známe metódy zaoberajúce sa vznikom takýchto algoritmov.

V praktickej časti sme sa venovali návrhom a realizáciám rôznych detektorov pre K-komplexy. Všetky tieto algoritmy boli založené na princípe kontrolovania príznakov charakterizujúcich vyhľadávané grafoelementy. Najprv sme sa zamerali na návrh prvej detekcie K-komplexov založenej na fuzzy prahových hodnotách, ktorej predspracovanie bolo realizované pomocou FIR filtrácie. Následujúca metóda bola navrhnutá na obdobnom princípe ako predchádzajúca. Hlavným rozdielom však bolo využitie IIR filtrácie na predspracovanie signálov. V poradí tretia metóda vychádzala z výpočtu energie signálu pomocou Teager-Kaiser energetického operátora. Základ posledných dvoch realizovaných metód spočíval v aplikácii vlnkovej transformácie a to u každej z nich rozdielnym spôsobom.

Všetky metódy sme následne testovali na reálnych spánkových záznamoch. Výstupy každej detekcie boli potom porovnávané s referenčnými hodnotami získanými spolu s databázou. V závere práce sa tak venujeme zhodnoteniu funkčnosti a predovšetkým účinnosti jednotlivých metód.

1 Elektroencefalografia

Medzi najdôležitejšie elektrické diagnostické metódy v oblasti spánkových štúdií je zaradená aj elektroencefalografia. Všeobecne je definovaná ako diagnostická metóda, poskytujúca informácie o elektrickej aktivite mozgu v čase. Všeobecne snímanie elektrických signálov môže prebiehať invazívne i neinvazívne. Invazívna metóda, ktorá zaznamenáva signály priamo z mozgovej kôry, čím je považovaná aj za presnejšiu, sa nazýva elektrokortikografia. Keďže sa nepodieľa v polysomnografii na získavaní potrebných informácií, nebude ďalej popisovaná. Neinvazívne snímanie je založené na princípe zaznamenávania rozdielu elektrických potenciálov medzi elektródami umiestnenými na pokožke hlavy. Výhodou tohto snímania je bezpečnosť a bezbolestnosť diagnostiky.


Zaznamenávanie EEG signálov pre účely spánkových štúdií má svoje špecifikácie. Všetky signály sú prenášané pomocou elektród a postupujú ďalej elektrickými káblami do zbernice polysomnografického zariadenia. Je možné sa stretnúť so zlatými elektródami, ktoré majú vo svojom strede otvor, ale sú používané aj povrchové Ag/AgCl elektródy. Priemer jednej takejto elektródy sa pohybuje v rozmedzí hodnôt od 0,4 cm až do 1 cm. Na zabezpečenie dobrej vodivosti medzi elektródou a kožou je vhodné používať vodivé gély alebo brúsne pasty, ktoré znižujú odpor kože v danom prechode. Ten je kontrolovaný samotným prístrojom a nemal by medzi párom elektród presahovať 5 M Ω , pretože vyššie hodnoty impedancie podporujú vznik nežiadúcich artefaktov z elektrickej siete [1].

Tab. 1.1: Popis použitých znakov v obrázku 1.1

Časť mozgu	L (vľavo)	V strede	R (vpravo)
Frontálna (čelová)	Fp1, F7, F3	Fpz, Fz	Fp2, F4, F8
Temporálna (spánková)	T3, T5	-	T4, T6
Centrálna (stredová)	C3	Cz	C4
Mastoidálna (ušná)	M1	-	M2
Parietálna (temenná)	P3	Pz	P4
Okcipitálna (záhlavná)	O1	Oz	O2

Rozdiel medzi klasickým elektroencefalografickým vyšetrením a použitím EEG počas polysomnografie je možné vidieť na obrázku 1.1 s vysvetlením jednotlivých znakov v tabuľke 1.1. Vľavo je zobrazené zapojenie elektród pri klasickom snímaní EEG a vpravo je zapojenie elektród počas spánkových štúdií. Hlavné odlišnosti sú teda v počte používaných elektród a ich zapojení. Je odporúčané používať minimálne tri referenčné zapojenia a to konkrétne F4, C4 a P4 merané všetky proti referencii

FRONTÁLNA ČASŤ LEBKY



OKCIPITÁLNA ČASŤ LEBKY

Obr. 1.1: Rozmiestnenie EEG elektród na hlave

na ľavom uchu M1. Toto použitie je nazývané ako kontralaterálne referenčné zapojenie. Referenčné práve preto, lebo signály zaznamenané z každej časti sú porovnávané s referenčnými signálmi získanými pomocou elektród umiestnených na ušiach. Čo však majú tieto merania spoločné je, že sa bez ohľadu na počet použitých elektród riadi ich umiestnenie medzinárodným systémom 10-20 [1].

1.1 Snímanie EEG signálov

Keďže sa pri snímaní EEG signálov používa veľké množstvo elektród, musí mať každá z nich svoju štandardizovanú pozíciu. Celá zostava takýchto elektród je následne pevne umiestnená na špeciálnej čiapke. Na pracovisku je možné sa stretnúť s rôznymi druhmi, rozlišovanými podľa počtu potrebných kanálov pre snímanie a podľa veľkosti. Všetky majú však jedno spoločné, riadia sa systémom 10-20. Tento systém je medzinárodne štandardizovaný pre popis a správne umiestnenie EEG čiapky vo všetkých klinických zariadeniach, od čoho sa následne odráža spoľahlivejšia reprodukovateľnosť výsledkov a správna diagnostika.

Názov tohto systému pochádza z toho, že každá elektróda, ktorá sa na čiapke

nachádza, je vzdialená od ďalšej elektródy presne o 10 % alebo 20 %. Celý mechanizmus spočíva v tom, že čiapka určuje orientačné body pre jednotlivé elektródy. Nimi sú označené individuálne časti mozgu, z ktorých snímame EEG signály. Každý takýto bod má svoj popis tvorený začiatočnými písmenami časti, ktorú zaznamenáva a číslom. Signály z každej elektródy sú zaznamenávané proti referenčnej elektróde. Túto elektródu je často možné si zvoliť. Spravidla sa však vyberajú buď elektródy na ušných lalokoch, stredová frontálna alebo stredová centrálna elektróda. Ďalšou zásadou je umiestnenie nepárnych čísel na ľavú stranu hlavy a párnych naopak na pravú stranu. Prehľad rozmiestnenia elektród je zobrazený na obrázku 1.1 vľavo pre klasické snímanie EEG a vpravo pre zapojenie EEG pri spánkových štúdiách.


1.2 EEG v polysomnografii

Polysomnografia je neinvazívna diagnostická metóda, ktorá je tiež označovaná ako komplexné monitorovanie spánku. Jej definícia sa odráža práve od toho, že našla využitie pri rozsiahlych štúdiách jednotlivých štádií spánku a tiež pri jeho anomáliách.

Aby bol polysomnograf schopný merať všetky potrebné dáta, musí pozostávať z množstva elektród a snímačov, ktoré sú situované na povrch tela. Mimo tejto meracej zostavy je dôležité podotknúť, že sa prístroj skladá zo samostatného počítača a zosilňovačov. Všetky vymenované komponenty sú nevyhnutnou riadiacou, archivačnou a vyhodnocovacou súčasťou celého prístroja.

Kedže metóda realizuje viaceré merania zároveň, tak konečný záznam, nazývaný polysomnogram, obsahuje radu dôležitých parametrov, ktoré po podrobnom nasnímaní dávajú informácie o trvaní, kvalite a správaní sa počas spánku. Konkrétne sa jedná o údaje nasnímané pomocou rozličných senzorov kontrolujúcich fyziologické prejavy počas spánku. Ďalej sú k tomuto meraniu pridružené aj údaje poskytnuté bežnými elektrickými diagnostickými prístrojmi. Konkrétne sa jedná o elektroencefalografiu, elektrookulografiu, elektromyografiu a elektrokardiografiu. Okrem vymenovaných základných súčastí, ktoré sú znázornené na obrázku 1.2, sa v dnešnej dobe využíva tiež video a audio záznam pre spoľahlivejšiu diagnostiku. Všetky merania prevádzané v PSG sú samozrejme synchronizované s ostatnými nahrávanými signálmi [2].

Ako bolo spomenuté tak jednou zo základných metód je aj snímanie EEG. Hlavnú úlohu zohráva pri klasifikácii spánkových štádií. Spánok je totiž nevyhnutný proces pre obnovu schopností, kognitívnej činnosti a riadenie organizmu. Pokiaľ je dodržiavaná dostatočne dlhá doba a kvalita spánku, prispieva to k celkovému fyzickému aj psychickému zdraviu jedinca. Všeobecne môže byť spánok definovaný ako prirodzená opakujúca sa forma odpočinku, počas ktorej sú utlmené reakcie na okolité podnety. V polysomnografických záznamoch býva odstupňovaný do 30s epoch, pomo-



Obr. 1.2: Ukážka zapojenia snímačov a elektród pri PSG vyšetrení - upravené z [3]

cou ktorých býva aj hodnotený. Každá epocha má pri hodnotení priradený stupeň spánku [4].

Všeobecne môžeme spánok deliť do dvoch od seba zásadne odlišných fáz. Názov prvej fázy, je odvodený z anglického non-rapid eye movements, čo v preklade predstavuje pomalé pohyby očí. Podľa toho je označovaná tiež ako NREM spánok. Pomenovanie druhej fázy vyplýva z výskytu vln rýchlych pohybov očí. Vďaka tomu je teda označovaná ako REM spánok. Prvý nastáva NREM spánok a po približne 90 až 120 min ho vystrieda spánok REM. Tieto fázy sa periodicky striedajú. Jeden cyklus obsahuje prežitie jedného REM a jedného NREM spánku vrátane jeho všetkých štádií. Za jednu noc tak dokáže zdravý jedinec prejsť približne štyrmi až šiestimi cyklami, ktoré v priemere trvajú 90 až 110 min. Dĺžka trvania samostatných štádií je veľmi premenlivá, pohybuje sa medzi 20 až 170 min. Všeobecne je však známe, že štádiá na začiatku a na konci spánku majú kratšie trvanie ako tie, ktoré sa nachádzajú uprostred [4].

Pre hodnotenie spánku je dôležité definovať nie len jednotlivé štádiá spánku, ale

aj štádium, ktoré predchádza jemu samotnému. Táto individuálna fáza sa nazýva bdelosť a býva označovaná písmenom W. Počas nej jedinec prechádza do počiatkových fáz ospalosti.

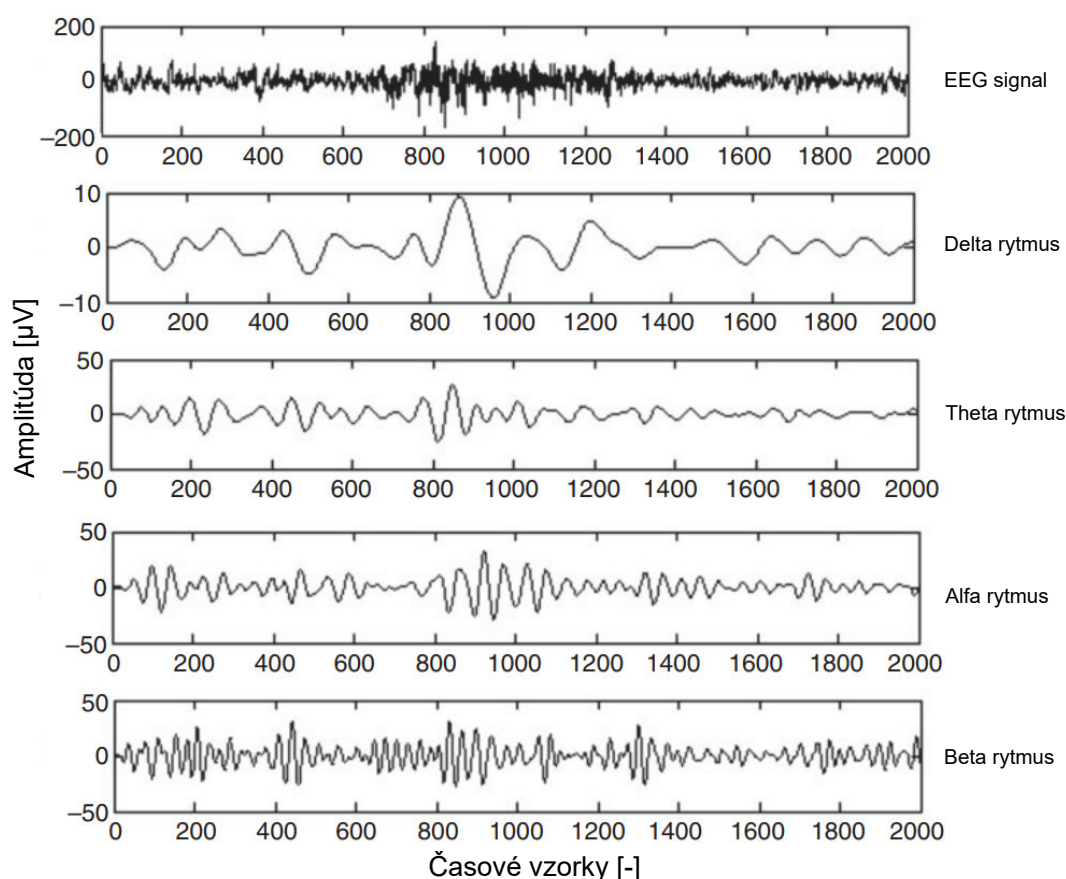
Zjednodušený prehľad všetkých fáz spánku je popísaný v tabuľke 1.2, ktorá je zameraná na popis frekvenčných pásiem a charakteristických znakov, pre každé spánkové štádium.

Tab. 1.2: Prehľad spánových fáz [1], [4]

Fázy spánku	Frekvencie	Charakteristické znaky
W	8 – 26 Hz	prechod do ospalosti vlny spôsobené pohybom očí na EOG pracujúce svaly a pohybové artefakty na EMG
N1	4 – 8 Hz	pomalé pohyby očí na EOG premenlivá, ale nie vysoká aktivita na EMG môžu sa objaviť ostré vlny na EEG
N2	4 – 8 Hz	spomalená frekvencia srdca zníženie telesnej teploty výskyt K-komplexov a spánkových vretien na EEG
N3	0 – 4 Hz	štádium najhlbšieho spánku vysoké hodnoty amplitúdy na EEG
REM	8 – 13 Hz	vysoká aktivita mozgu minimálna aktivita na EMG možný výskyt snov zrýchlená frekvencia srdca zrýchlené a nepravidelné dýchanie

Odlíšenie spomínaných fáz spánku je možné aj vďaka typickým vzorom vyskytujúcich sa na EEG záznamoch. Sú to vlastne oscilácie delené podľa špecifických parametrov a to hlavne podľa rozmedzí frekvencií, amplitúdy a tvaru. Všeobecne známymi rytmiami vyskytujúcimi sa na záznamoch sú delta, theta, alfa a beta, ktoré je možné vidieť na obrázku 1.3. Ďalej sa však môžeme stretnúť s rôznymi grafoelementami, medzi ktoré patria hlavne spánkové vretená, K-komplexy, pomalé vlny a ostré vlny vertexu [1].

Ako delta rytmus sú nazývané vlny s frekvenciou od 0 Hz do 4 Hz. Ich frekvencie nepresahujú veľkosť amplitúdy väčšiu ako 100 μ V. Pozorované bývajú najmä v čelnej oblasti. Indikujú hlboký spánok, čo znamená, že ich výskyt bude hlavne v spánkovom štádiu N3. Theta rytmus je spozorovaný pri frekvenciách od 4 Hz do 8 Hz s rovnako veľkými amplitúdami ako sa vyskytujú v delta rytme. Ako sme



Obr. 1.3: Frekvenčné rozdelenie rytmov v EEG signále - upravené z [5]

už spomínali, spozorované bývajú najmä v štádiách N1 a N2. Vznikajú v oblasti centrálnych vrcholov a považujú sa za najčastejšie frekvencie spánku. Označenie alfa rytmus nesú vlny, ktoré sa objavujú na zázname v rozmedzí od 8 Hz do 13 Hz s amplitúdou nižšou ako 10 μV . Vytvára ich zväčša okcipitálny lalok mozgu, ktorý zodpovedá za vizuálne schopnosti človeka. Objavujú sa v stave bdlosti a so zatvorením očí sú lepšie viditeľné. Významnými charakteristikami sú tiež synchronnosť a symetrickosť. Tvar sa približuje sínusovému signálu. Mali by sme však vedieť rozlíšiť aj ďalší rytmus vyskytujúci sa v rozmedzí frekvencií alfa vln. V tomto intervale sa totiž môžeme stretnúť s takzvaným mu rytmom, ktorý zodpovedá synchronnému toku motorických neurónov nad senzoro-motorickou kôrou. Tieto vlny sa niekedy zmiešajú alebo len prekrývajú s inými. Ďalšie vlny s frekvenciami od 13 Hz do 26 Hz sú nazývané ako beta rytmus. Tie majú amplitúdy s veľkosťou menšou ako 20 μV . Zvyčajne sú spozorované v čelných a centrálnych oblastiach, čo nevylučuje ich výskyt aj na inom mieste. Zaznamenávané sú počas normálneho stavu vedomia a vďaka

Tab. 1.3: Frekvenčné rozdelenie rytmov v EEG signále - zhrnutie

Rytmus	Frekvencie	Amplitúda	Výskyt
Delta (δ)	0 - 4 Hz	$< 100 \mu\text{V}$	hlboký spánok
Theta (θ)	4 - 8 Hz	$< 100 \mu\text{V}$	spánok
Alfa (α)	8 - 13 Hz	$< 10 \mu\text{V}$	bdelosť
Mu (μ)	8 - 13 Hz	-	prúd motorických neurónov
Beta (β)	13 - 26 Hz	$< 20 \mu\text{V}$	vedomie
Gama (γ)	30 Hz a viac	-	zmiešané senzorické spracovanie

tomu nemajú synchrónny charakter. Pri frekvenciách vyšších ako 30 Hz sa môžeme stretnúť v ľudskom mozgu s gamma rytmom. Jeho výskyt býva podmienený priebehom zmiešaného senzorického spracovania, keď jedinec používa kombináciu dvoch a viacerých zmyslov naraz [1], [6].

1.3 Spracovanie spánkových EEG signálov

Po umiestnení všetkých elektród a snímačov na pacienta prichádza druhá podstatná časť, ktorou je samotné spracovanie signálov, čo znamená získanie všetkých potrebných informácií, pre ktoré sme meranie vykonávali. Aj keď už pri samotnom meraní sú prevádzané určité druhy filtrácií dát z elektród, nestačia nám pre hodnotenie signálu. Keďže sa počas hodnotenia spánku stretávame s mnohými vzormi poskytujúcimi klinicky významné informácie, je praktickejšie a rýchlejšie spánkové signály analyzovať pomocou počítačovej techniky.

Náročné býva jednotne charakterizovať spánkové EEG signály, keďže majú nestacionárny charakter. Nie len to, ale aj výskyt všetkých pridružených komponentov nám stále znemožňuje nájsť všeobecne použiteľné algoritmy k ich správne spracovávaniu a analýze. Existuje množstvo metód aplikovaných v tejto oblasti, ktoré sú založené na rôznych technikách. Všetky prístupy k vyvíjaniu funkčných detekčných algoritmov majú spoločný štandardný principiálny prístup vývoja. Ten je založený na modelovaní základných procesov a používaní vzniknutého modelu na vývoj optimálnych algoritmov. Za ich základné komponenty sú považované pedspracovanie, extrakcia zložiek a klasifikácia funkcií predstavujúcich podstatnú úlohu v automatizovanej analýze spánkových signálov [7].

Pod pojem pedspracovanie sa väčšinou zahrňujú úpravy signálov ako kalibrácia, normalizácia a úprava dispozície. Tie sú však zhodné v mnohých oblastiach zaoberajúcich sa spracovaním signálov. Pri spánkových EEG signáloch je potrebné sa zamerať skôr na individuálne prístupy spojené s analýzou a to na spracovanie arte-

faktov a ich extrakciu z nameraných dát. Tieto komponenty sa nachádzajú v každom biologickom signále a majú chaotický efekt pri interpretácii zaznamenatej funkcie, pretože nebývajú spôsobené skúmanými fyziologickými prejavmi. Ak ich však vieme identifikovať, môže byť zvážení ďalší postup, ktorým artefakt buď filtrujeme alebo časť signálu úplne odstránime [7].

V prvom rade si musíme uvedomiť, že pri nahrávaní viackanálového signálu, môžeme zaznamenávať na niektorých kanáloch aj korelované signály. Tie pôsobia nadbytočne a je vhodné ich odstrániť, pretože sa s nimi znižuje efektívnosť spracovávania. Nápomocnými môžu byť metódy nezávislej analýzy komponentov, následovne analýzy hlavných komponentov a tiež separačné techniky [8].

Pre zachovanie celistvosti signálu sa vo väčšine prípadov volí možnosť detekcie a odstránenia len rušivej zložky. Detekčným prístupom môže byť významná odchýlka od normy alebo použitie energetického operátora. Je samozrejme nutné dbať pri aplikácii týchto prístupov na možnosť odstránenia dôležitých diagnostických ukazovateľov, kvôli nestálemu charakteru nielen EEG signálu, ale aj samotných nežiadúcich komponentov. Ako vhodnejšie metódy sa naskytujú techniky potlačovania artefaktov pomocou nastaviteľných filtrov. Selektívne filtre sú zvyčajnou súčasťou pri eliminácii artefaktov, ktoré sa nachádzajú v rozdielnych frekvenčných pásmach, čo je v reálnych prípadoch výnimočné. V takom prípade sa môžeme pokúsiť o získanie referenčného signálu, ktorý nie je kontaminovaný artefaktom a zamietnuť jeho prospešnosť. To môžeme docieľiť využitím Wienerových filtrov, adaptačnou filtráciou, regresiou časovej alebo frekvenčnej oblasti. Účinnosť týchto metód je však obmedzená kvalitou referenčného snímania. Nádejnou metódou sa stala teda analýza nezávislých komponentov, ktorá rozkladá údaje signálu do množiny náhodných nezávislých premenných. Používa sa najmä pre odstránenie elektromagnetických artefaktov a interferencie v sieti. Hlavným problémom však je enormné množstvo a automatická identifikácia spojená so separovaním zložiek signálu EEG a nežiadúcich komponentov, čo však nevylučuje jej použiteľnosť v praxi [7].

Pri snímaní akýchkoľvek biologických elektrických signálov nie je možné zaznamenať dokonale čistý záznam. Vždy sa v ňom vyskytujú ďalšie zložky, ktoré musia byť rozpoznané ako už bolo spomenuté. Niektoré sú totiž pre daný záznam rušivé, tie nazývame artefakty a iné môžu byť diagnosticky prospešné, tie nazývame grafoelementy. Je samozrejmé, že artefakty sa snažíme pred, počas aj po meraní, čo najviac obmedziť a filtrovať. Naopak grafoelementy majú tak významnú funkciu, že sa ich snažíme detegovať, poprípade aj zvýrazniť.

1.3.1 Artefakty

Pri meraní biologických signálov je možné zaznamenávať spolu s užitočnými signálmi nechcene aj artefakty z elektrických diagnostických prístrojov. Tie sú väčšinou spôsobené vplyvmi prostredia, pohybmi pacienta, nesprávnou aplikáciou elektród, ostatnými prístrojmi v okolí alebo samotnou elektrickou sieťou. Charakterizuje ich najmä nezvyčajný vzhľad a tendencia znižovať vernosť i reprodukovateľnosť meraných signálov.

Artefakt spôsobený elektródami môže byť nasnímaný z viacerých dôvodov. Prvým je úplné odstránenie elektródy z miesta, na ktorom pôvodne bola. To býva obvykle zapríčinené nadmernými pohybmi pacienta počas spánku. Ďalšou príčinou býva použitie malého množstva vodivého gélu. Pri tejto nedostatočnej aplikácii gélu, je pravdepodobné, že vyschne a tým pádom môže dôjsť k posunu elektród. Nie je vylúčené ani to, že môže byť omylom aplikovaná poškodená elektróda a tým sa objavia na zázname taktiež nežiadúce artefakty. To však nedefinuje elektródy ako jediný zdroj výskytu nežiadúcich vzorov v EEG.

Veľmi často sa stretávame s artefaktami fyziologickými, ktoré nemajú mozgový pôvod, ale aj napriek tomu sú na EEG zázname viditeľné. V prvom prípade sa môže tento typ objaviť vtedy, ak má meraný nejaké defekty lebky, tým sa myslia poškodenia ako zlomeniny v oblasti hlavy, od detstva nezrastené švy a iné. Defekty dovoľujú snímať vyššie hodnoty napätia. Tento artefakt sa zvyčajne objaví pri zaznamenávaní vyšších frekvencií. Obmedziť ho nemôžeme, ale dá sa naň dopredu pripraviť pri anamnéze pacienta. Ako s ďalším sa stretávame s EKG artefaktami. Množstvo z nich vzniká v dôsledku fyziologickej funkcie srdca a to v závislosti na vzdialenosti elektród od neho. No nie len samotné srdce, ale aj cievne riečisko na hlave môže spôsobiť nežiadúci výskyt periodického vzoru. Na ich obmedzenie sa často používa časová súčinnosť EKG a EEG, čo dovoľuje ľahko definovať tieto vzory pri hodnotení záznamov. Pohyby očí spôsobujú rovnako nežiadúce vzory v signáloch EEG. Charakterizované sú najmä veľkou pozitívnou vlnou bez ohľadu na smer oka. Že ide o výskyt týchto artefaktov a nie o diagnosticky významné grafoelementy, môžeme zistiť porovnaním so záznamami z EOG. Medzi veľmi časté sa radia aj svalové artefakty, ktorých rozlišujeme niekoľko druhov. Môžu byť spôsobené pohybom jazyka, žuvaním alebo svalmi pod pokožkou hlavy. Často bývajú dobre rozlíšiteľné vďaka ich vyšším frekvenciám, amplitúde a aktivite [4].

Existujú však rôzne špecifikované artefakty, ktoré nemajú pre nás klinický význam, ale nie sú filtrované pre nedostatočnú poprípade nestálu charakteristiku ich vln. Časovou synchronizáciou všetkých meracích súčastí im však môžeme porozumieť a nebrať ich ďalej v úvahu. Aby bola, čo najlepšie zobrazená diagnosticky zaujímavá činnosť, musíme vedieť artefakty rozpoznať a väčšinu z nich dobre fil-


trovať. Filtrácia závisí od individuálnych nastavení celej meracej sústavy, čo sa týka oblasti frekvencií.

1.3.2 Grafoelementy

Mimo základných vln charakterizujúcich jednotlivé spánkové štádiá a vznikajúcich artefaktov sa v signáli EEG objavujú ďalšie prechodné udalosti. Sú nazývané ako grafoelementy a radia sa medzi ne hlavne K-komplexy, spánkové vretená, pomalé vlny, vlny s ostrým vrcholom, vlny pomalých aj rýchlych pohybov očí a vlny s tvarom zubov píly. Väčšinou sú prepojené s patologickými javmi, preto je dôležité ich správne detegovať.

K-komplexmi sú označované typické grafoelementy vyskytujúce sa na zázname spánkového EEG. Spozorované sú najmä v kanáloch z frontálnych oblastí mozgu a zároveň bývajú symetricky zaznamenané na oboch hemisférach. Zvyčajne sú zložené z ostrých, jednofázových alebo polyfázických vln s prudkou negatívnou deformáciou, po ktorej nasleduje pomalá pozitívna vlna. Pre ich identifikáciu je stanovené trvanie, ktorého dĺžka musí dosahovať aspoň 0,5 s. Majú väčšinou veľkú hodnotu amplitúdy vystupujúceho spoza nízkonapäťového pozadia. Pomocou nich býva stanovené štádium N2, v ktorom sa vyskytujú spolu so spánkovými vretenami, ktoré sa nachádzajú pred alebo za týmito komplexmi. Ich výskyt však s časom klesá a zároveň sa objavujú menej a menej v každom ďalšom spánkovom cykle. V ideálnom prípade ich nájdeme zreteľne vymedzené, no v reálnom zázname je ich výskyt komplikované určiť, pretože sa ich frekvenčný rozsah zhoduje alebo prekrýva priamo s delta vlnami a ostrými vlnami vertexu. Mimo týchto hlavných znakov by bolo vhodné podotknúť, že postupom veku sa znižuje amplitúda a frekvencia K-komplexov, čo môže byť významným kritériom pri návrhoch detekčných algoritmov a hlavne pri ich testovaní na rôznych dátach [9], [10].

Ďalšími segmentmi spánkového EEG signálu sú spánkové vretená. Majú striedajúci sa vzostupne-zostupný charakter. Sú prejavmi thalamu a thalamokortikálnych dráh s rozsahom frekvencií od 12 Hz do 16 Hz. To znamená, že ich najlepšie zaznamenáme pomocou elektród umiestnených v centrálnej časti hlavy. Celková dĺžka týchto elementov je 0,5 s až 1,5 s. Ich funkcia nie je presne stanovená. Okrem charakteristického výskytu v štádiu N2 sa môžu objavovať aj v N3 štádiu. Štádium N3 býva určené pomocou vln s pomalou frekvenciou v rozmedzí 0,5 Hz až 2 Hz. Amplitúda presahuje väčšinou 75 μ V v signále z frontálnych kanálov. Vlny pozorované na začiatku spánku sú vlny s ostrými hrotmi, ktorých názov sa odvíja od ich typickej formy v signále. Sú to totiž ostro vymedzené negatívne vlny presahujúce aktivitu na pozadí. Majú vysokú amplitúdu a nachádzajú sa v oblasti vysokých frekvencií. Ich výskyt je výrazný hlavne z kanálov v okolí Cz elektródy a netrvajú viac ako



Obr. 1.4: Ukážka niektorých grafoelementov v surovom EEG signále

0,5 s. Na zázname EEG ich môžeme spozorovať najmä pri prechode z N1 štádia do N2. V bdelosti a taktiež v spánkovom štádiu N1 môžeme pomocou EEG zaznamenať taktiež pomalé pohyby očí, ktoré s prechodom do fázy N2 postupne miznú. Tieto združené a pomerne pravidelné sínusové vzory trvajú väčšinou dlhšie ako 0,5 s. Ak však spozorujeme združené vlny, ktorých trvanie je kratšie ako 0,5 s, hovoríme o rýchlych pohyboch očí. Vyznačujú sa nepravidelnosťou a ostrými vrcholmi vln. Bývajú znamením REM spánku. Okrem vzorov rýchlych pohybov očí je často veľmi nápomocný výskyt vln podobných theta aktivite mozgu. Tie sa označujú podľa ich charakteristického tvaru zubov píly. Frekvenčne sa pohybujú medzi 2 Hz až 6 Hz. Ich trvanie je časovo variabilné, preto nie je možné ho definovať. V centrálnych kanáloch dosahujú maximálnu amplitúdu [9], [10].

1.3.3 Metódy spracovania spánkových EEG

K spracovávaniu nestacionárnych biologických signálov sa často používa segmentácia v časovej oblasti. Vykonáva sa jeho rozdelením na krátke úseky, ktoré je možné pokladať za približne stacionárne. Vďaka ich nemennosti počas trvania signálu môžu byť popísané ich charakteristické vlastnosti. Segmentácia býva realizovaná buď rovnomerne alebo nerovnomerne. V oblasti predspracovania je najčastejšie používané rovnomerné rozdelenie signálu na pravidelné úseky s dĺžkou 30, 20 alebo 1 s, ktorá závisí od požadovanej citlivosti. Dlhšie segmenty spôsobujú vysokú početnú náročnosť a môžu vytvárať nereálne výsledky. Výber adekvátnej dĺžky závisí hlavne na type použitého algoritmu, od ktorého sa odvíja dôveryhodnosť výsledkov. Väčšinou sa k takejto segmentácii využíva krátkodobá Fourierova transformácia, ktorá je však

obmedzovaná použitím pevnej dĺžky pohyblivého okna. To býva zbytočné pri úsekoch, ktoré sa dlhšiu dobu nemenia a aj napriek tomu sú delené na množstvo úsekov. Sofistikovanejšou metódou sa preto javí používanie adaptívnej segmentácie. Jej princíp je založený na analýze základného signálu pre stanovenie vhodnej dĺžky segmentov. Výhody spočívajú v detekcii približne stacionárnych úsekov signálu, v ktorých môžeme použiť dlhšie segmenty bez významného ovplyvnenia a straty informácie. Naopak pri úseku signálu, ktorý je časovo premenlivý, je možné zvoliť kratšie úseky [7], [8].

Je množstvo spôsobov a postupov ako získať zo signálu potrebné dáta. Extrakčné techniky slúžia pre výber skúmaných vzorov z pozadia, pretože poskytujú informácie o reálnej štruktúre signálu. Väčšinou sa nepoužíva len jedna funkcia, ktorá by dokonale poskytla potrebné informácie. Pri analýze signálu je teda možné na základe kvantitatívnych znakov extrahovať zo záznamu podobné úseky.

Jednou z možností analýzy štruktúry signálu je použitie krátkodobých štatistických odhadov a iných metód odhadu zastúpenia spektrálnych zložiek. Konkrétne sú využívané funkcie ako priemer, variácia, hľadanie prechodov nulou, autokorelačné funkcie, hodnota výkonovej spektrálnej hustoty alebo štatistické metódy vyšších radov. Všetky tieto metódy sa realizujú pomocou pohyblivého okna. Informácie nimi poskytnuté charakterizujú variabilitu a zložitosť signálu z rôznych hľadísk. Okrem toho môžu slúžiť k testovaniu stacionarity a odhaleniu nedostatkov signálu [8].

Najviac využívanými parametrami zo spánkových EEG sú spektrálne funkcie, ktoré poskytujú informácie o frekvenčnej oblasti signálu. Poznáme dva druhy týchto funkcií, parametrické a neparametrické. Neparametrické metódy ako napríklad periodogram a Welchova metóda, využívajú pre výpočet frekvenčných zložiek priamo Fourierovu transformáciu. Naopak parametrické metódy, ku ktorým patria automatické regresie, adaptívne autoregresné modely, časovo premenné autoregresné modelovanie a Kalmanove filtre, používajú na odhad spektrálnych zložiek prispôbený matematický model signálu [7].

Mimo spomenutých metód sa používajú aj časovo-frekvenčné analýzy, ktoré sú založené na sledovaní vývoja frekvencií v čase. To je veľmi dôležité pri analýze spánkových EEG, pretože tie obsahujú náhle zmeny amplitúd a frekvencií v čase. Môžeme tu zaradiť vlnkovú filtráciu, krátkodobú Fourierovu transformáciu, Wigner-Ville transformácia a mnoho ďalších [7].

Ďalšími používanými sú nelineárne metódy, ktoré poskytujú doplnujúce informácie pri charakteristike špecifických priebehov v signále. Sú založené na nelineárnej dynamickej analýze [7].

Po extrakcii skúmaných znakov je vhodné previesť klasifikáciu. Tá umožňuje zoskupiť znaky, ktoré majú medzi sebou určitú podobnosť, do viacerých kategórií na základe miery tejto podobnosti. Najpoužívanějšími sú klasifikácie pomocou neuró-

nových sietí, zhlukovanie, štatistické klasifikácie, fuzzy klasifikácie alebo kombinované klasifikátory. Problémom, ktorý sa naskytuje pri týchto funkciách, je neschopnosť vytvoriť optimálne hranice pre rozhodovanie [7].

Vymenované postupy a metódy sú aplikovateľné priamo na spánkové EEG signály. V týchto signáloch môžeme spozorovať mnohé diagnosticky potrebné vzory, ktoré majú špecifickejšie prístupy k ich následnej detekcii. Tieto prístupy však nie sú všeobecne aplikovateľné na všetky záznamy a tak nie je možné pri hodnotení odstrániť subjektivitu. V tejto práci sa ďalej zameriame na možnosti návrhu detekcie K-komplexov.

2 Možnosti detekcie K-komplexov

Všeobecne sú K-komplexy nevyhnutné pre stanovenie N2 štádia spánku, ktoré určuje prechod z ospalosti do hlbšieho spánku. Mimo to sa môžu vyskytovať aj v odpovedi na elektrostimuláciu [11].

Hodnotenie na základe vizuálneho pozorovania spánkového EEG záznamu je časovo veľmi náročná činnosť. Okrem toho pri porovnávaní výsledkov od rôznych expertov môžeme zistiť, že sa málokedy zhodujú a sú teda zafarbené subjektivitou. Pre detekciu K-komplexov boli vytvorené detekčné algoritmy, ktoré neboli zatiaľ štandardizované pre veľkú rozmanitosť spánkových záznamov aj samotných grafoelementov. Medzi hlavné metódy, na ktorých sú založené algoritmy, patria napríklad detekcie pomocou vlnkovej transformácie, fuzzy prahových hodnôt a Teager-Kaiser energetického operátora. V nasledujúcej časti tejto kapitoly vysvetlíme všeobecnú funkciu a základný princíp hlavných metód používaných v detekčných algoritmoch. Väčšina detekcií však nie je vytvorená len na princípe jednej metódy. Každý detekčný algoritmus vychádzajúci z nich má totiž viaceré súčasti, ktoré prispievajú k samotnej detekcii [11].

2.1 Metóda s výpočtom vlnkovej transformácie

Vlnková transformácia, ktorá je základom nejedného detekčného algoritmu, je v skutočnosti skôr súborom transformácií s rovnakými znakmi, ktoré sa odlišujú od seba podľa tvaru zvolenej bázevej funkcie. Signál tak môžeme vyjadriť lineárnou kombináciou vlniek. Zásadným odlišovacím znakom oproti iným transformáciám je ten, že každá bázevá funkcia má nenulové hodnoty len na konečnom časovom intervale. Mimo tento interval tak spozorujeme nulové alebo zanedbateľne malé hodnoty. Pomocou vlnkovej transformácie môžeme vykonávať teda časovo-frekvenčnú analýzu signálov [12].

Konkrétne túto metódu používali autori v článku [13], ktorí pomocou vlnkovej transformácie vytvorili poloaufomatický detekčný algoritmus pre vyhľadávanie K-komplexov v spánkovom signále. Ako vstupy použili nie len jednokanálové EEG, ale aj hypnogram, ktorý im umožnil extrahovať signál v N2 fáze spánku. Pomocou tejto transformácie bolo možné zviditeľniť aj K-komplexy, ktorých parametre ďalej porovnávali s prahovými hodnotami. Pokiaľ nájdený grafoelement nespĺňal stanovené minimálne hraničné hodnoty, tak bol algoritmom zamietnutý a odstránený. Výstup bol binárny a tak označoval len skutočnosť výskytu reálnych K-komplexov a všetky zamietnuté vzory označil ako frekvencie pozadia. Autori článku spomínajú taktiež následné testovanie na dvoch rôznych databázach, čo bolo však sťažované odlišnosťami v zbere údajov, použitého kanálu EEG a veku meraných subjektov.

Preto museli pristúpiť na manuálne nastavovanie prahových hodnôt. Po testovaní algoritmu na rôznych databázach sa zistilo, že aj pri ručnom nastavení rôznych prahových hodnôt je väčšina chýb detekcie spôsobená rozmanitosťou spánkových EEG záznamov u rôznych subjektov. Tým sa dostali k záveru, že detekčný algoritmus dokáže hodnotiť správne K-komplexy, no manuálne nastavovanie hodnôt nie je výhodné z hľadiska spoľahlivosti a všeobecnej použiteľnosti. Bolo by tak vhodné pokračovať v ďalšom rozšírení tohto poloautomatického algoritmu na plne automatický [13].

2.2 Metóda pracujúca s fuzzy prahovými hodnotami

Používaním fuzzy logiky môžeme ľahšie zhlukovať príznaky určitých vzorov. Každému príznaku je priradená miera príslušnosti, ktorá je podľa dopredu zvolených parametrov a funkcií počítaná algoritmom. Tá vyjadruje s akou pravdepodobnosťou sa prahové hodnoty približujú optimálnemu K-komplexu. Podľa týchto parametrov potom môžeme ďalej vylúčiť nájdený falošný K-komplex alebo naopak potvrdiť, že detekcia prebehla úspešne.

Detekciou s využitím fuzzy prahových hodnôt sa zaoberali autori v článku [11]. Ich algoritmus je založený na výpočte hraničných bodov K-komplexu, ktoré sú následne porovnávané s referenčnými hodnotami pre tieto grafoelementy. Následne je každému nájdenému možnému K-komplexu priradená určitá miera príslušnosti. Táto hodnota musí mať hraničnú veľkosť, pre ktorú bude K-komplex algoritmom buď prijatý ako reálny alebo zamietnutý a zároveň označený za falošne pozitívny [11].

Podrobnejším vysvetlením tejto metódy sa zaoberá nasledujúca kapitola 3.1, v ktorej sa zameriame na určité parametre a praktický popis detekčného algoritmu.

2.3 Metóda s využitím Teager-Kaiser energetického operátora

Teager-Kaiser energetický operátor je nelineárny operátor používaný pre odhad okamžitej energie signálu, ktorý závisí na prvých dvoch derivátoch signálu. TKEO je vhodný pri spracovávaní signálov z rôznych oblastí [14].

Pre extrakciu a následnú detekciu bol mimo iného aj TKEO využitý v algoritme, ktorý navrhli autori článku [14]. Tento energetický operátor vychádza z prvých dvoch derivácií, čo môžeme vidieť z rovnice v diskretnom čase.

$$y = x^2(n) + x(n-1) * x(n+1) \quad (2.1)$$

Tým, že výpočet prebieha v tak malom okne, je vhodný pre lokálnu analýzu signálov. Použitie tohto operátora je tiež zdôvodnené výhodami, konkrétne medzi ne patrí napríklad potláčanie prechodových účinkov a aktivity pozadia [14].

2.4 Štatistické vyhodnocovanie účinnosti detektorov

Všetky realizované detektory sa musia dať porovnať na základe určitých parametrov, ktoré percentuálne vyjadria ich funkčnosť a samotnú účinnosť. Keďže počet nájdených K-komplexov v signáloch nie je vhodným vyhodnocovacím prvkom správnosti, je vhodné sa zamerať na vyhodnocovanie pomocou štatistických hodnôt.

Pre porovnanie navrhnutých detektorov existujú viaceré štatistické parametre. Medzi najčastejšie používané patria:

- senzitivita (Se) - určuje pravdepodobnosť s akou dokáže systém označiť reálne K-komplexy nachádzajúce sa v signále ako skutočné

$$Se = \frac{TP}{TP + FN} * 100 \quad (2.2)$$

TP - označuje počet správne detegovaných K-komplexov, ktoré označil detektor aj odborník a FN - určuje počet zaznamenaných K-komplexov odborníkom, ktoré detektor nespoznal

- špecificita (Sp) - udáva pravdepodobnosť s akou bude detekcia negatívna, práve keď nebude prítomný K-komplex v signále

$$Sp = \frac{TN}{TN + FP} * 100 \quad (2.3)$$

TN - vyjadruje počet K-komplexov, ktoré nevyhovujú jeho morfológii a tak neboli označené ani odborníkom ani detektorom a naopak FP - predstavuje počet K-komplexov detegovaných algoritmom bez potvrdenia u odborníka

- pozitívna prediktívna hodnota (PPV) - stanovuje pravdepodobnosť, že ide o skutočný K-komplex, keď bol detektorom označený ako skutočný

$$PPV = \frac{TP}{TP + FP} * 100 \quad (2.4)$$

- negatívna prediktívna hodnota (NPV) - definuje pravdepodobnosť, že nejde o K-komplex, keď nebol detektorom nájdený

$$NPV = \frac{TN}{TN + FN} * 100 \quad (2.5)$$

- presnosť (Acc) - určuje pomer správne detegovaných K-komplexov

$$Acc = \frac{TP + TN}{TP + FP + TN + FN} * 100 \quad (2.6)$$

- chyba (Err) - určuje pomer nesprávne detegovaných K-komplexov

$$Err = (1 - Acc) * 100 \quad (2.7)$$

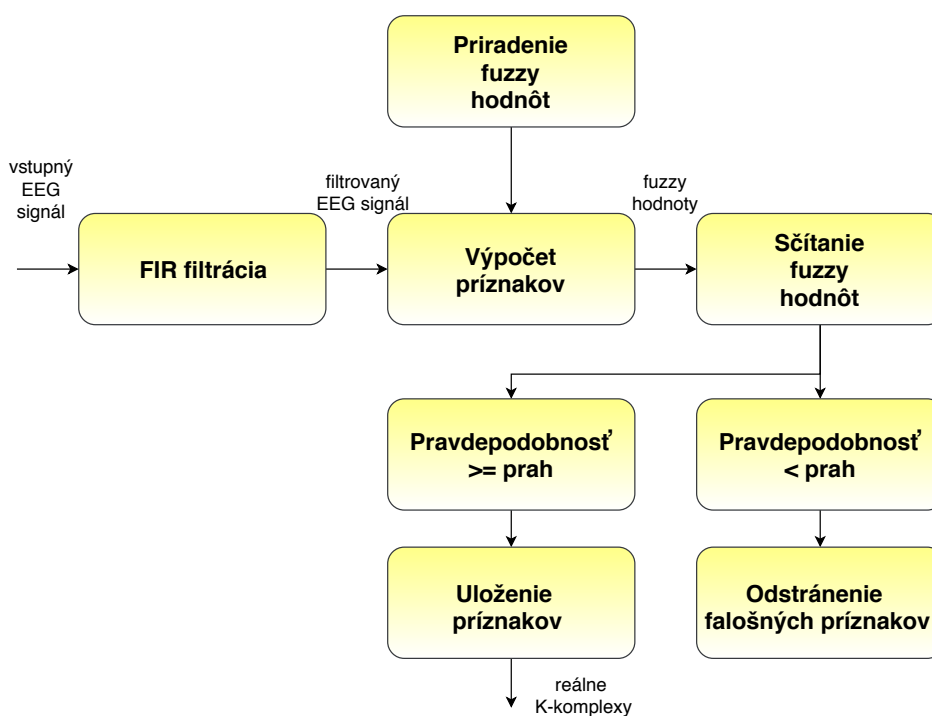
V nasledujúcich kapitolách sa budeme zameriavať na štatistické vyhodnotenie každej z metód zvlášť a nakoniec na porovnanie podľa vopred získaných hodnotení od referencií. Za referencie považujeme s databázou poskytnuté hodnotenia od dvoch expertov (E1 a E2) a od neznámeho automatického detektoru (AD). Po uvážení sme sa rozhodli, že v našom prípade by bolo vhodné sa zamerať hlavne na senzitivitu a pozitívnu prediktívnu hodnotu navrhnutých detekčných algoritmov, aby sme čo najjasnejšie ohodnotili výkonnosť a optimálnosť detektorov oproti referenciám.

3 Návrh a realizácia detekcie K-komplexov

Táto kapitola obsahuje popis návrhu a realizácie niekoľkých metód pre detekciu K-komplexov v programovacom prostredí MATLAB R2018b. K tomu sme použili databázu so signálmi nameranými v spánkovom laboratóriu v belgickej nemocnici (BrainnetTM Systém MEDATEC, Brusel). Dáta boli získané pomocou digitálneho 32 kanálového polygrafu so vzorkovacou frekvenciou 200 Hz. Databáza teda obsahuje extrahované 30 min úseky 10 EEG signálov od zdravých jedincov z N2 oblasti spánku hodnotené dvomi expertmi a automatickým detektorom.

3.1 Detekcia K-komplexov s využitím fuzzy prahových hodnôt (FIR)

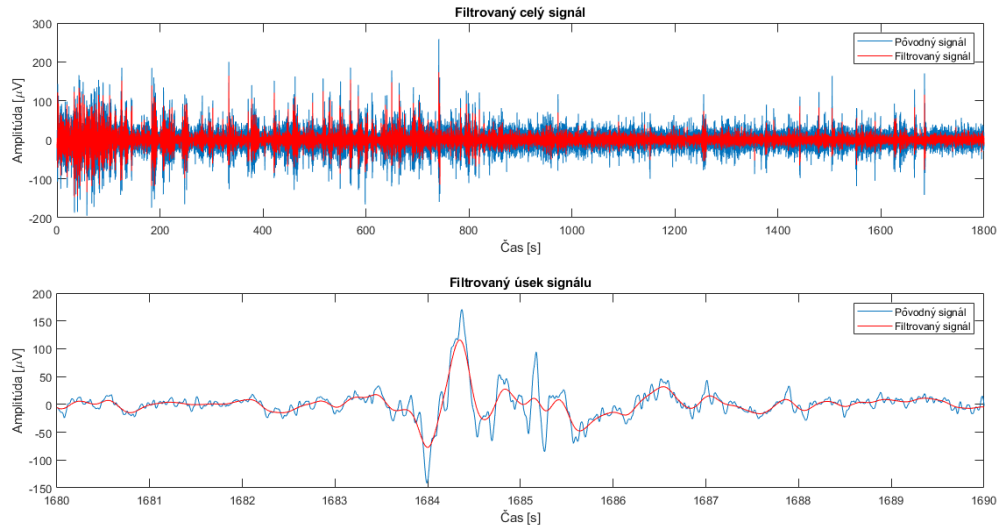
Návrh tohto algoritmu sa odvíjal od už existujúcej metódy popísanej v článku [11], ktorého blokovú schému je možné vidieť na obrázku 3.1. Detekčný algoritmus je založený na extrahovaní vlastností a následnom použití pravdepodobnostných prahových hodnôt, ktoré sú porovnávané v každom kroku detekcie s objaveným možným K-komplexom. To znamená, že na výstupe sa objavili hodnoty miery príslušnosti, pomocou ktorých po stanovení prahovej hodnoty vhodnej pre prijatie vzoru, bol algoritmus schopný rozlíšiť reálne a falošné výskyty K-komplexov.



Obr. 3.1: Bloková schéma navrhnutého algoritmu pre detekciu K-komplexov

3.1.1 Predspracovanie a extrakcia príznakov


Najdôležitejšou časťou, na ktorej závisí každý detekčný algoritmus, je predspracovanie signálu. V našej detekcii sme tak previedli FIR filtráciu pomocou matlabovskej funkcie `fir1`. Najprv sme aplikovali hornú priepusť s medznou frekvenciou 0,5 Hz a následne sme použili dolnú priepusť s medznou frekvenciou 3,5 Hz. Tento krok je zobrazený na obrázku 3.2, kde je ukážka ako celého signálu, tak aj jeho 10 s detailu.



Obr. 3.2: Porovnanie signálu pred a po FIR filtrácii

Nasledujúcou významnou časťou algoritmu je extrakcia príznakov K-komplexu. V tomto kroku začíname hľadaním lokálnych miním a maxím v celom filtrovanom signále. Pomocou nich je ďalej možné určiť významné body K-komplexu, ktoré sú zobrazené na obrázku 3.3. Medzi zisťované premenné patria:

- t_{min} a val_{min} - súradnice nájdeného minima možného K-komplexu
- t_{max} a val_{max} - súradnice nájdeného maxima možného K-komplexu v intervale $[t_{min}, t_{min}+1 \text{ s}]$
- t_{start} - časová súradnica začiatku možného K-komplexu, tzn. prvý bod väčší ako $val_{min}/2$ hľadaný smerom doľava od t_{min}
- t_{end} - časová súradnica konca možného K-komplexu, tzn. prvý bod väčší ako t_{max} v oblasti, kde je signál nižší ako $-5 \mu\text{V}$
- t_{mid1} - časová súradnica preklápania negatívnej vlny na pozitívnu, tzn. prvý bod väčší ako $0 \mu\text{V}$ hľadaný zľava doprava od t_{min}
- t_{mid2} - časová súradnica preklápania negatívnej vlny na pozitívnu, tzn. prvý bod menší ako $-5 \mu\text{V}$ hľadaný sprava doľava od t_{end}



Obr. 3.3: Ukážka príznakov na reálnom K-komplexe

3.1.2 Výpočet príznakov

Pri rozhodovaní prijatia uvedených príznakov sme sa inšpirovali funkciami v článku, z ktorého sme vychádzali. Tieto funkcie predstavujú určité podmienky pre prijatie K-komplexu ako reálneho. Preto sme vytvorili funkciu *realKC.mat*, ktorá obsahovala výpočty nižšie popísaných príznakov.

Základnou podmienkou K-komplexu je to, že jeho doba trvania sa pohybuje v intervale od 0,5 - 1,5 s. To overíme vypočítaním f_1 [11]:

$$f_1 = t_{end} - t_{start} \quad (3.1)$$

Pokračujeme overením skutočnosti, že po negatívnej vlne nasleduje bezprostredne pozitívna, pomocou príznaku f_2 [11]:

$$f_2 = \frac{t_{mid2} - t_{mid1}}{f_1} \quad (3.2)$$

Ďalším dôležitým príznakom je výpočet f_3 , v ktorom zisťujeme dostatočnú veľkosť amplitúdy, ktorá by v reálnom K-komplexe mala byť väčšia ako 100 μV [11].

$$f_3 = val_{max} - val_{min} \quad (3.3)$$

Následne zisťujeme, či má nájdený grafoelement dostatočnú amplitúdu v porovnaní s pozadím EEG. Za pozadie považujeme 2 s signálu pred nájdenou hodnotou t_{start} , ktoré vypočítame ako priemernú hodnotu pomocou rovníc m_1 a m_2 . K tomu nám slúži rovnica f_4 , kde f_{vz} označuje vzorkovaciu frekvenciu signálu [11]:

$$m_1 = mean(signal((i_{start} - 2 * f_{vz}) : i_{start}, 1)) \quad (3.4)$$

$$m_2 = \text{mean}(\text{signal}(i_{\text{start}} - 4 * f_{vz} : i_{\text{start}} - 2 * f_{vz}, 1)) \quad (3.5)$$

$$f_4 = \frac{f_3}{\min(m_1, m_2)} \quad (3.6)$$

Kvôli prítomnosti artefaktov nám to však nemusí postačovať, takže sme pridali ďalšiu funkciu f_5 , ktorá počíta celkovú amplitúdu pozadia signálu v 15 s, ktoré možný K-komplex obklopujú [11]:

$$f_5 = \text{mean}(\text{signal}((i_{\text{start}} - 7 * f_{vz}) : i_{\text{end}} + 7 * f_{vz}, 1)) \quad (3.7)$$

Ďalšia funkcia f_6 slúži na zamietnutie príliš vysokej strednej hodnoty amplitúdy pozadia EEG [11]:

$$f_6 = \frac{f_3}{f_5} \quad (3.8)$$

Podľa kritérií by mala amplitúda negatívnej vlny mať veľkosť aspoň 50 % z amplitúdy pozitívnej vlny. Pre zistenie tejto skutočnosti sme použili funkciu f_7 [11]:

$$f_7 = \frac{\text{abs}(val_{\min})}{val_{\max}} \quad (3.9)$$

Dôležité je tiež zistenie ostrosti negatívnej vlny v porovnaní s pozitívnou, ktorú zabezpečuje výpočet funkcie f_8 [11]:

$$f_8 = \frac{t_{\text{end}} - t_{\text{mid1}}}{t_{\text{mid1}} - t_{\text{start}}} \quad (3.10)$$

Keďže tieto kritéria neboli najvhodnejším riešením, tak bol napokon pridaný ďalší príznak f_9 [11]:

$$f_9 = \frac{\text{abs}(val_{\min})}{(t_{\text{mid1}} - t_{\text{start}}) * f_{vz}} \quad (3.11)$$

Pred koncom sme použili výpočet funkcie f_{10} [11]:

$$f_{10} = \frac{f_3}{f_1 * f_{vz}} \quad (3.12)$$


Nechýbalo taktiež doplnenie funkcie f_{11} , ktorá kontroluje podmienku v časovej následnosti K-komplexov:

$$f_{11} = \text{signal}(i_{\text{start}}, 1) - \text{signal}(i_{\text{end}} - (1 * f_{vz}), 1) \quad (3.13)$$

Pomocou vypočítaných príznakov následne dokážeme odmietnuť detegované príznaky vzorov, ktoré nezodpovedajú štandardným charakteristikám.


3.1.3 Výstup detekcie

K tomu, aby sme mohli príznaky zamietnuť alebo naopak potvrdiť, potrebujeme hodnoty miery príslušnosti, ktoré zodpovedajú stupňu príslušnosti skúmaného vzoru do skupiny K-komplexov. Tie boli priradené každému výstupu z vypočítaných funkcií.



Obr. 3.4: Ukážka výslednej detekcie príznakov K-komplexov

Pomocou týchto hodnôt sme následne vypočítali pravdepodobnosti potvrdzujúce výskyt K-komplexu. Pri testovaní sme zistili, že výsledná hodnota vyššia ako 0,59 by mala označovať reálny výskyt detegovaného K-komplexu. Výsledky nami navrhnutého detektoru je možné vidieť na obrázku 3.5.



Obr. 3.5: Ukážka navrhutej detekcie K-komplexov v porovnaní s expertom

3.1.4 Účinnosť realizovanej metódy

Metóda využívajúca fuzzy hodnoty je veľmi perspektívna, pretože umožňuje prijať K-komplexy s mierne odlišujúcou sa morfológiou. Pre kvantitatívne porovnanie účinnosti navrhnutého algoritmu uvádzame najprv tabuľku 3.1, v ktorej sa nachádzajú detegované K-komplexy realizovanou metódou a získané z referencií.

Tab. 3.1: Množstvo nájdených K-komplexov v signáloch databázy

Názov	Expert 1	Expert 2	Auto. detektor	Navrhnutý detektor
Signál 1	34	19	22	84
Signál 2	45	8	37	53
Signál 3	12	3	14	19
Signál 4	78	14	63	210
Signál 5	39	20	40	74

Keďže počet K-komplexov nie je vhodným ukazovateľom správnosti detekcie, tak sme sa zamerali ďalej na niektoré vhodnejšie štatistické pramaterie. Pre navrhnutý detektor sme ďalej vypočítali spomenuté štatistické hodnoty, ktoré sú zobrazené v tabuľke 3.2 pre každú referenciu. V tabuľke detektor označuje počet nájdených K-komplexov navrhnutým detektorom a zhoda vyjadruje počet K-komplexov detegovaných ako nami navrhnutým detektorom, tak aj odborníkom. Hodnoty senzitivity a pozitívnej prediktívnej hodnoty sú uvedené v percentách.

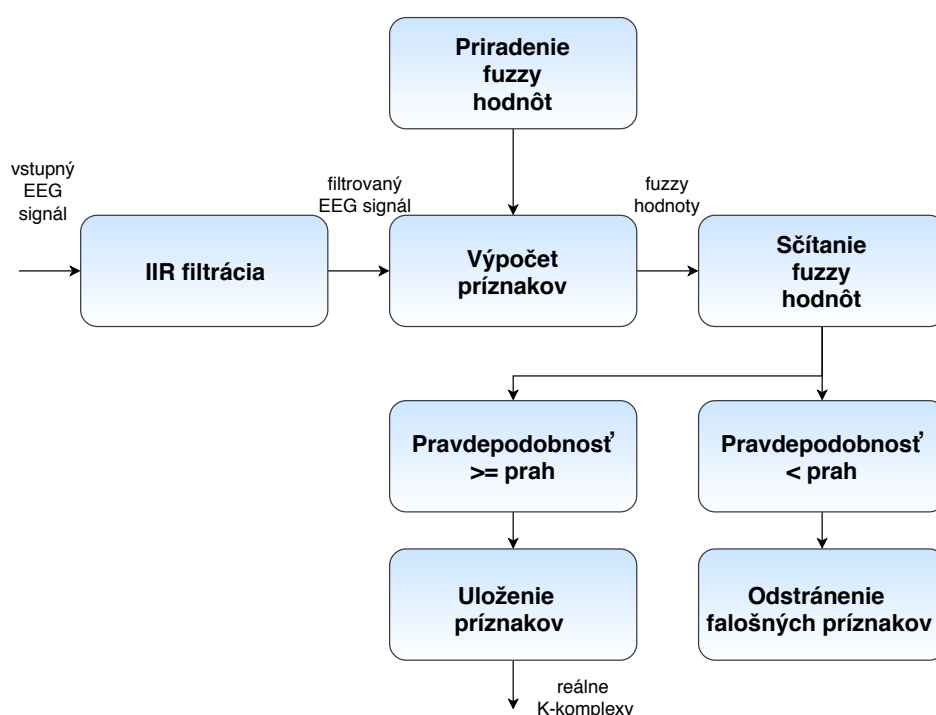
Tab. 3.2: Prehľad štatistických hodnôt pre porovnanie s referenciami

	Názov	Signál 1	Signál 2	Signál 3	Signál 4	Signál 5
Detekcia	Počet	70	48	0	121	60
Expert 1	Počet	34	45	12	78	39
	Zhoda	23	30	0	48	32
	<i>Se</i>	67,65	66,67	0	61,54	82,05
	<i>PPV</i>	32,86	62,50	0	39,67	53,33
Expert 2	Počet	19	8	3	14	20
	Zhoda	8	7	0	10	14
	<i>Se</i>	42,11	87,50	0	71,43	70,00
	<i>PPV</i>	11,43	14,58	0	8,26	23,33
A. detektor	Počet	22	37	14	63	40
	Zhoda	11	22	0	33	25
	<i>Se</i>	50,00	59,46	0	52,38	62,50
	<i>PPV</i>	15,71	45,83	0	27,27	41,67

Podľa dopočítaných štatistických údajov môžeme ďalej usúdiť, že táto metóda by mala byť ešte optimalizovaná, aby sme dosiahli lepšie výsledky. Jedná sa hlavne o signál č.3, v ktorom navrhnutý algoritmus nenašiel ani jeden K-komplex. To mohlo byť zapríčinené jeho odlišnosťou od ostatných testovaných signálov.

3.2 Detekcia K-komplexov s využitím fuzzy prahových hodnôt (IIR)

Ako ďalší sme sa rozhodli navrhnúť algoritmus zakladajúci sa na podobnom princípe ako v predchádzajúcej kapitole 3.1, ktorého bloková schéma je na obrázku 3.6.



Obr. 3.6: Bloková schéma navrhnutého algoritmu pre detekciu K-komplexov


V tomto prípade sme však zvolili filtráciu iného typu, upravili sme počet kontrolovaných príznakov, veľkosti prahových hodnôt a tiež pravdepodobnostných hodnôt. Taktiež sme nezabudli zmeniť prahovú hodnotu pre prijatie príznakov ako skutočných K-komplexov.

3.2.1 Predspracovanie

Tentokrát bolo kľúčové využiť filtre s nekonečnou impulznou charakteristikou, konkrétne sme použili Butterworth filter druhého radu ako dolnú priepuť s medznou

frekvenciou 3,5 Hz. Následne sme aplikovali na signál Chebyshev filter druhého typu a tiež druhého radu. Tento filter realizoval hornú priepusť s medznou frekvenciou 0,5 Hz. Výstup tejto časti je zobrazený na obrázku 3.7, kde je možné vidieť vyfiltrovaný celý signál a v spodnej časti tiež jeho detail.

Pri porovnaní s filtráciou v predchádzajúcej kapitole môžeme vidieť, že IIR filter nadmerne neskresľuje signál. Za dôležité považujeme najmä zachovať, resp. čo najmenej zmeniť veľkosti amplitúdy poskytnutého signálu. Ďalším dôležitým faktorom je aj samotné vyhladenie signálu. Aj keď môžeme vidieť v tejto oblasti mierne nerovnosti, dovoľíme si uviesť, že nemajú zásadne negatívny vplyv na samotné vyhladávanie K-komplexov. Preto sa javí ako lepšie riešenie predspracovania EEG spánkových signálov práve IIR filtrácia.



Obr. 3.7: Porovnanie signálu pred a po IIR filtrácii


3.2.2 Extrakcia a prijatie príznakov

Samotná extrakcia príznakov bola založená na podobnom princípe ako v predchádzajúcej kapitole 3.1. Významné body pre následné výpočty príznakov sme ponechali a sú zobrazené na obrázku 3.8.

Pre kontrolu príznakov sme vytvorili funkciu *IIRrealKC.mat*, pomocou ktorej sme kontrolovali šesť základných. K základným príznakom patrí vhodná dĺžka trvania, ktorú sme vypočítali pomocou funkcie f_1 :

$$f_1 = t_{end} - t_{start} \quad (3.14)$$

Ďalej nás zaujímala veľkosť pozitívnej amplitúdy val_{max} , vďaka ktorej sme následne zisťovali vhodnú veľkosť negatívnej amplitúdy pomocou f_2 :



Obr. 3.8: Významné body K-komplexu

$$f_2 = \frac{abs(val_{min})}{val_{max}} \quad (3.15)$$

Nezaobíšli sme sa tiež bez kontroly veľkosti pozadia 8 s pred začiatkom K-komplexu v dvoch intervaloch. Najprv sme zistili amplitúdu prostredníctvom m_1 v prvých 4 s pred i_{start} a následne pomocou m_2 ďalšie 4 s. Obidva tieto úseky museli byť minimálne dvakrát menšie ako amplitúda zisťovaného K-komplexu.

Následovalo zisťovanie minimálneho sklonu K-komplexu, f_3 :


$$f_3 = \frac{f_2}{t_{max} - t_{min}} \quad (3.16)$$

Posledný príznak overoval, či sa v nasledujúcich sekundách vyskytuje ďalší K-komplex. Keďže sa väčšinou dva po sebe idúce K-komplexy vyskytujú s približne 2,5 s medzerou, tak sme priradili blízko sa vyskytujúcim menšie fuzzy hodnoty.

Na základe vypočítaných funkcií boli stanovené pravdepodobnostné hodnoty pre každý jeden kontrolovaný príznak. Z tých bola následne vypočítaná priemerná pravdepodobnostná hodnota reálneho výskytu.

3.2.3 Výstup detekcie

Na základe spomínaných priemerných pravdepodobnostných hodnôt sme mohli určiť skutočnosť, či sa jedná o detekciu reálneho K-komplexu. To bolo možné len vtedy ak vypočítaná hodnota presiahla prah 0,60. Na výstupe sme teda obdržali detegované K-komplexy v porovnaní s hodnotením experta. Na obrázku 3.9 je zobrazený výsledok detekcie v prvom testovanom signále.



Obr. 3.9: Ukážka navrhnutej detekcie K-komplexov v porovnaní s expertom

3.2.4 Účinnosť realizovanej metódy

Kedže predchádzajúca metóda nebola schopná detegovať signál č.3 a nevyhovovala tak predstavám o univerzálne funkčnom algoritme, tak sme sa rozhodli ju modifikovať a navrhnúť tak algoritmus na podobnom princípe s IIR filtráciou a inými vyhľadávanými príznakmi. Tabuľka 3.3 slúži pre porovnanie množstva nájdených K-komplexov vo všetkých piatich testovacích signáloch oproti referenčným hodnotám z databázy.

Tab. 3.3: Množstvo nájdených K-komplexov v signáloch databázy

Názov	Expert 1	Expert 2	Auto. detektor	Navrhnutý detektor
Signál 1	34	19	22	65
Signál 2	45	8	37	37
Signál 3	12	3	14	5
Signál 4	78	14	63	102
Signál 5	39	20	40	57

Porovnanie účinnosti medzi touto navrhnutou metódou a referenčnými hodnotami v piatich signáloch z databázy je zobrazené v tabuľke 3.4. Z uvedených dopočítaných štatistických hodnôt môžeme usúdiť, že sa podarilo navrhnúť o niečo lepšiu metódu ako je tá v predchádzajúcej kapitole. O dokonalosti však vraviť nemôžeme, pre stále prevládajúce množstvo falošne pozitívnych výsledkov.

Tab. 3.4: Prehľad štatistických hodnôt pre porovnanie s referenciami

	Názov	Signál 1	Signál 2	Signál 3	Signál 4	Signál 5
Detekcia	Počet	65	37	5	102	57
Expert 1	Počet	34	45	12	78	39
	Zhoda	22	30	3	51	28
	<i>Se</i>	64,71	66,67	25,00	65,38	71,79
	<i>PPV</i>	33,85	81,08	60,00	50,00	49,12
Expert 2	Počet	19	8	3	14	20
	Zhoda	10	7	1	10	17
	<i>Se</i>	52,63	87,50	33,33	71,43	85,00
	<i>PPV</i>	15,38	18,92	20,00	9,80	29,82
A. detektor	Počet	22	37	14	63	40
	Zhoda	11	23	3	36	26
	<i>Se</i>	50,00	62,16	21,43	57,14	65,00
	<i>PPV</i>	16,92	62,16	60,00	35,29	45,61


3.3 Detekcia K-komplexov s využitím Teager-Kaiser energetického operátora

Koncept návrhu algoritmu bol čerpaný z článku [14]. Základným prvkom tohto detektoru je vypočítať energiu signálu. Následne je možné vyhľadávať ďalšie príznaky, pomocou ktorých postupne odstraňujeme prebytočné pôvodne nájdené možné lokality K-komplexov. Tie, ktoré neboli odstránené ani v jednom kroku, čo znamená, že mali nadprahové vlastnosti, sú považované za maximá reálnych K-komplexov. Na obrázku 3.10 je možné vidieť blokovú schému algoritmu.

3.3.1 Predspracovanie

Prvým krokom bola opäť filtrácia vstupného EEG signálu. Pre túto metódu sme zvolili konkrétne hornú priepusť s medznou frekvenciou 0,5 Hz, dolnú priepusť s medznou frekvenciou 5 Hz a následne pásmovú zádrž v oblasti frekvencií 45 - 55 Hz. Všetky použité filtre boli typu Butterworth piateho radu.


Pri testovaní sme odskúšali viacero medzných frekvencií pre dolnú priepusť a to konkrétne v rozsahu od 3,5 Hz do 6,5 Hz. Následné štatistické hodnotenie preukázalo použitie konečne zvolenej medznej frekvencie 5 Hz za najlepšie z ohľadom na senzitivitu navrhovaného detektoru. Ďalej môžeme poukázať na to, že tento typ filtrácie vyhladil nepotrebné zložky a pri tom nespôsobil rapídne skreslenie amplitúdy. Signál pred a po filtrácii pre porovnanie je možné vidieť na obrázku 3.11.




Obr. 3.10: Bloková schéma navrhnutého algoritmu pre detekciu K-komplexov

3.3.2 Extrakcia a odstraňovanie príznakov

Po predspracovaní sme aplikovali na signál Teager-Kaiser energetický operátor. Na výstupe sme obdržali energiu signálu zobrazenú na obrázku 3.12. Následne boli extrahované lokálne maximá EEG signálu. Keďže sa väčšina signálu nachádza v kladnej oblasti, tak nám reprezentovali možné K-komplexy.



Obr. 3.11: Porovnanie signálu pred a po filtrácii



Obr. 3.12: Energia signálu získaná aplikáciou TKEO


Aby sme mohli falošné vzory odstrániť, určili sme si charakteristické príznaky pre K-komplex, ktorými sme postupne overovali jeho výskyt. Hľadané príznaky je možné vidieť na obrázku 3.13 a patria k nim:

- $start_{KC}$ - určuje začiatok kladnej amplitúdy K-komplexu, hľadaný je od lokálneho maxima smerom doľava
- end_{KC} - označuje koniec kladnej amplitúdy K-komplexu, hľadaný je od lokálneho maxima smerom doprava
- $ampl_{thr}$ - je hraničná hodnota pre porovnanie trvania amplitúdy v tomto mieste
- KC_{m1} - popisuje počiatočnú hodnotu, z ktorej počítame trvanie amplitúdy v oblasti $ampl_{thr}$
- KC_{m2} - popisuje konečnú hodnotu, z ktorej počítame trvanie amplitúdy v oblasti $ampl_{thr}$

Pre každý nájdený možný K-komplex sme teda počítali dĺžku trvania kladnej amplitúdy, ktorá nemohla byť menšia ako 250 ms. Ak túto podmienku spĺňala, tak sme pokračovali v zisťovaní druhej podmienky, kde trvanie signálu v oblasti $ampl_{thr}$ muselo byť dlhšie ako 50 ms. Po splnení aj tejto podmienky sa následne overovala ešte skutočná amplitúda v pôvodnom signále, ktorá musela byť minimálne 64 μV , aby bol K-komplex prijatý.


3.3.3 Výstup detekcie

Pokiaľ na začiatku detegovaný možný K-komplex nespĺňal všetky zo spomínaných podmienok, tak bol okamžite odstránený. Po kroku odstraňovania nám teda ostali na výstupe reálne K-komplexy. Na obrázku 3.14 je možné vidieť výstup navrhutej



Obr. 3.13: Ukážka vyhľadávaných príznakov

detekcie v porovnaní s hodnotením experta v prvom testovanom signále. Pre lepšiu predstavu uvádzame nie len výsledok v celom signále, ale aj v jeho 70s úseku.



Obr. 3.14: Ukážka nájdených K-komplexov v porovnaní s expertom

3.3.4 Účinnosť realizovanej metódy

Ďalšou navrhnutou a realizovanou metódou detekcie K-komplexov bol algoritmus využívajúci Teager-Kaiser energetický operátor. Táto detekcia je založená na najmenšom počte zisťovaných príznakov a to sa vzápätí odráža aj na jej výstupe, ktorý

je viditeľný ako na obrázku 3.14, tak aj v tabuľke 3.5. Tá zobrazuje počet nájdených K-komplexov spolu s referenčnými hodnotami.

Tab. 3.5: Množstvo nájdených K-komplexov v signáloch databázy

Názov	Expert 1	Expert 2	Auto. detektor	Navrhnutý detektor
Signál 1	34	19	22	62
Signál 2	45	8	37	33
Signál 3	12	3	14	3
Signál 4	78	14	63	116
Signál 5	39	20	40	52

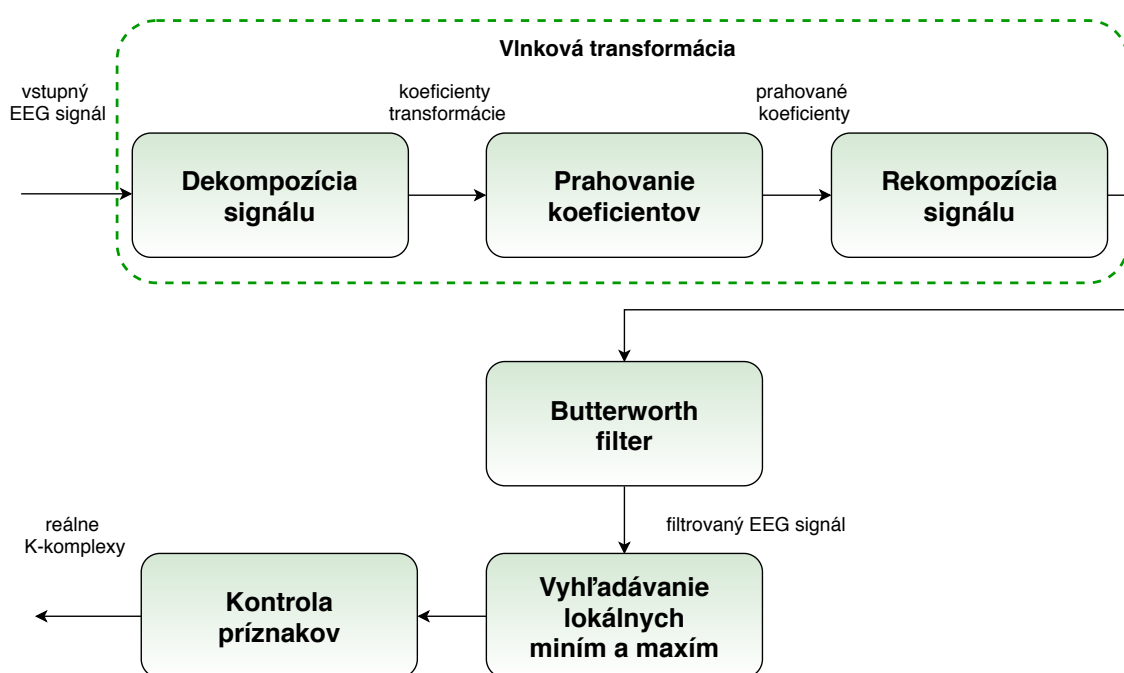
Celkovú účinnosť metódy však udávajú následne dopočítané štatistické parametre, ktoré sú zhrnuté v tabuľke 3.6. Z tých môžeme usúdiť, že nami navrhnutý detektor má celkom slabú detekčnú účinnosť. To vyplýva hlavne z pozitívnej prediktívnej hodnoty, ktorá vo viac ako polovici prípadoch nedosiahla ani úrovne 30 %. Aj keď sa senzitivita tejto metódy drží v okolí 50 %, nezabezpečuje to maximálnu dôveryhodnosť tejto metódy. Hodnoty vypočítané pomocou štatistických metód boli ovplyvnené aj tým, že detektor v signále č.3 opäť nezaznamenal ani jeden zhodný K-komplex.

Tab. 3.6: Prehľad štatistických hodnôt pre porovnanie s referenciami

	Názov	Signál 1	Signál 2	Signál 3	Signál 4	Signál 5
Detekcia	Počet	62	33	3	116	52
Expert 1	Počet	34	45	12	78	39
	Zhoda	22	23	0	46	19
	<i>Se</i>	64,71	51,11	0	58,97	48,72
	<i>PPV</i>	35,48	69,70	0	39,66	36,54
Expert 2	Počet	19	8	3	14	20
	Zhoda	9	5	0	10	12
	<i>Se</i>	47,37	62,50	0	71,43	60,00
	<i>PPV</i>	14,52	15,15	0	8,62	23,08
A. detektor	Počet	22	37	14	63	40
	Zhoda	10	19	0	33	14
	<i>Se</i>	45,45	51,35	0	52,38	35,00
	<i>PPV</i>	16,13	57,58	0	28,45	26,92

3.4 Detekcia K-komplexov s využitím vlnkovej transformácie

Návrh algoritmu bol zostavený na základe metódy popísanej v článku [14]. Hlavným komponentom algoritmu je predspracovanie signálu pomocou vlnkovej transformácie. Ďalej boli ako zvyčajne vyhľadávané charakteristické znaky pre K-komplex, na základe ktorých bude prijatá skutočnosť výskytu K-komplexu. Na obrázku 3.15 je zobrazená bloková schéma navrhnutého algoritmu.



Obr. 3.15: Bloková schéma navrhnutého algoritmu


3.4.1 Predspracovanie

Na filtráciu signálu sme najskôr použili stacionárnu vlnkovú transformáciu, ktorá je oproti ostatným typom vlnkových transformácií časovo invariantná, tým pádom považujeme jej aplikáciu za vhodnejšie riešenie pre predspracovanie spánkového signálu v tomto prípade [7].

Táto transformácia nám podľa stupňa rozloženia a podľa použitia materskej vlnky, najprv spánkový signál rozloží na frekvenčne odlišné subpásma. V našom prípade sme aplikovali vlnku *sym4* so 4. stupňom rozkladu, ktorá je tvarom podobná

hľadanému grafoelementu. Po dekompozícii sme na koeficienty aplikovali prahovanie, ktoré zabezpečuje, aby mal EEG signál reálne hodnoty amplitúdy. To je dôležité najmä z hľadiska zisťovania príznakov a samotného vyhľadávania K-komplexov. Následne sme mohli na koeficienty použiť spätnú stacionárnu vlnkovú transformáciu, pomocou ktorej sme signál zrekonštruovali.

Kedže nám to neposkytlo dostatočnú filtráciu signálu, rozhodli sme sa aplikovať ešte IIR filter typu Butterworth štvrtého radu a s medznou frekvenciou 3,5 Hz. Tento krok je zobrazený na obrázku 3.16, kde môžeme vidieť postupnú zmenu signálu po každom kroku predspracovania.




Obr. 3.16: Porovnanie signálu pred a po predspracovaní

3.4.2 Extrakcia a odstraňovanie príznakov

Po dostatočnej filtrácii sme vyhládali v signále lokálne minimá a maximá. Každá dvojica zložená z minima a maxima teda predstavovala prvotné K-komplexy.

Pre overenie štandardných charakteristík možných K-komplexov sme si stanovili pár hlavných bodov, viditeľných na obrázku, a to hlavne:

- $start_{min}$ - označuje začiatok negatívnej vlny K-komplexu
- end_{min} - určuje koniec negatívnej vlny K-komplexu
- $trueKC_{min}$ - definuje vrchol negatívnej vlny K-komplexu
- $start_{max}$ - symbolizuje začiatok pozitívnej vlny K-komplexu
- end_{max} - je koniec pozitívnej vlny K-komplexu
- $trueKC_{max}$ - definuje vrchol pozitívnej vlny K-komplexu



Obr. 3.17: Ukážka hľadaných bodov

Hľadané body nám slúžili pre počítanie vybraných funkcií, ktorých hodnoty museli vyjsť väčšie ako stanovený prah. Ako prvý sme počítali sklon K-komplexu podľa funkcie:

$$slope = \frac{y_{max} - y_{min}}{x_{max} - x_{min}} \quad (3.17)$$


Ďalej sme pokračovali kontrolou amplitúdy pozadia, kde sme prechádzali 4 s úsek signálu pred možným K-komplexom v dvoch intervaloch. Podmienkou bolo, aby v tomto úseku nebola nájdená vyššia amplitúda. Tento príznak je vyhľadávaný kvôli obmedzeniu falošne pozitívnych výsledkov, ktoré by miesto detekcie K-komplexu mohli detegovať práve aktivitu pozadia.

Následne kontrolovanou dôležitou charakteristikou K-komplexu je aj jeho celkové trvanie, ktoré musí byť väčšie ako 0,5 s. Takže sme súčet medzi nájdenými bodmi $start_{min}$ a end_{max} porovnávali s prahom t_{total} , ktorý stanovoval minimálny prah pre dobu trvania K-komplexu. Po tom sme skontrolovali trvanie kladnej a zápornej amplitúdy nájdeného vzoru osobitne. Každá z nich musela trvať aspoň $t_{total}/4$. Ako posledná bola kontrolovaná aj samotná veľkosť amplitúdy kladnej a tiež zápornej vlny.

3.4.3 Výstup detekcie

Aj v tomto algoritme sme postupovali vyradovacou metódou, čo znamená, že ak nájdené body nespĺňali aspoň jednu podmienku, boli okamžite odstránené. Výslednú detekciu v prvom testovanom signále je možné vidieť na obrázku 3.18, kde prvýkrát

môžeme vidieť značné obmedzenia v detekcii falošných K-komplexov v prvých 200 s signálu.



Obr. 3.18: Ukážka nájdených K-komplexov v porovnaní s expertom

3.4.4 Účinnosť realizovanej metódy

Navrhovaný a realizovaný algoritmus vychádzal z filtrácie pomocou vlnkovej transformácie. Ukázalo sa, že vhodná kombinácia filtrácie a hľadaných príznakov, zaručila spomedzi navrhovaných metód doposiaľ najlepšie výsledky. Značné rozdiely oproti ostatným navrhovaným metódam môžeme vidieť aj v samotnom počte detegovaných K-komplexov, ktoré zobrazuje tabuľka 3.7.

Tab. 3.7: Množstvo nájdených K-komplexov v signáloch databázy

Názov	Expert 1	Expert 2	Auto. detektor	Navrhnutý detektor
Signál 1	34	19	22	48
Signál 2	45	8	37	33
Signál 3	12	3	14	9
Signál 4	78	14	63	86
Signál 5	39	20	40	66

Pre prehľad uvádzame ďalšiu tabuľku 3.8, z ktorej môžeme usúdiť, že senzitivita vo všetkých testovaných signáloch neklesla pod úroveň 50 %. Pri pohľade na pozitívnu prediktívnu hodnotu môžeme skonštatovať, že sa pohybuje vo veľmi veľkom rozmedzí a to približne od 11 % až do 84 %. To síce nie je vhodné, ale môžeme to


Tab. 3.8: Prehľad štatistických hodnôt pre porovnanie s referenciami

	Názov	Signál 1	Signál 2	Signál 3	Signál 4	Signál 5
Detekcia	Počet	48	33	9	86	66
Expert 1	Počet	34	45	12	78	39
	Zhoda	23	28	6	48	33
	<i>Se</i>	67,65	62,22	50,00	61,54	84,62
	<i>PPV</i>	47,92	84,85	66,67	55,81	50,00
Expert 2	Počet	19	8	3	14	20
	Zhoda	11	4	2	10	18
	<i>Se</i>	57,89	50,00	66,67	71,43	90,00
	<i>PPV</i>	22,92	12,12	22,22	11,63	27,27
A. detektor	Počet	22	37	14	63	40
	Zhoda	11	24	7	35	30
	<i>Se</i>	50,00	64,86	50,00	55,56	75,00
	<i>PPV</i>	22,92	72,73	77,78	40,70	45,45

odôvodniť tým, že sú k databáze priložené veľmi rozličné hodnotenia od jednotlivých expertov.

3.5 Detekcia K-komplexov s využitím dekompozície pomocou vlnkovej transformácie


Myšlienka návrhu tejto metódy vznikla po realizácii detekcie popísanej v kapitole 3.4 a to hlavne pre jej zložitý koncept. Zjednodušenie spočívalo vo vynechaní prahovania, rekompozície a následného filtrovania signálu. Takže sme v tomto prípade postupovali nasledujúcimi krokmi. Najprv sme použili vlnkovú transformáciu pre dekompozíciu signálu, v ktorom sme ďalej hľadali minimá a maximá signálu. Tieto dvojice sme opäť považovali za prvotné K-komplexy, čo sa však zmenilo v kroku kontroly príznakov. Základný postup je viditeľný na blokovej schéme zobrazenej na obrázku 3.19.



Obr. 3.19: Bloková schéma navrhnutého algoritmu

3.5.1 Predspracovanie

Základnou súčasťou tohto algoritmu bolo predspracovanie aplikovaním vlnkovej transformácie. V tomto prípade sme pre rozklad signálu použili materskú vlnku db3 s 5. stupňom rozkladu. Tým sme získali pásmo signálu v oblasti 3,125 Hz, na ktorý sme už narozdiel od predchádzajúceho prípadu neaplikovali žiadny filter. Výstup tohto kroku je možné vidieť na obrázku 3.20, kde je zobrazený celý filtrovaný signál a tak tiež jeho 10 s úsek.




Obr. 3.20: Porovnanie signálu pred a po predspracovaní

3.5.2 Extrakcia a odstraňovanie príznakov

Tak ako v predchádzajúcich prípadoch sme pokračovali vyhľadávaním príznakov, ktoré by mohli charakterizovať hlavné znaky hľadaného K-komplexu. Prvými vyhľadávanými bodmi boli opäť lokálne minimá a maximá filtrovaného signálu. Tie označili možný výskyt reálnych K-komplexov.


Keďže tento návrh slúžil hlavne pre porovnanie účinnosti s predchádzajúcou metódou, tak sme sa rozhodli vyhľadávať úplne rovnaké príznaky, ktoré sú zobrazené na obrázku 3.21. Pomocou týchto bodov sme následne mohli kontrolovať sklon grafoelementu a jeho pozadie v okolí 4 s. Ďalej sme vyhodnocovali dostatočnú dĺžku trvania celého K-komplexu, jeho kladnej a tiež zápornej vlny. Ako posledné bola kontrolovaná celková amplitúda nájdeného K-komplexu a tiež jeho negatívna amplitúda. Hlavná zmena spočívala teda v používaní iných prahových hodnôt, keďže signál bol inak predspracovaný.



Obr. 3.21: Ukážka hľadaných bodov

3.5.3 Výstup detekcie

Pri kontrolovaní príznakov boli opäť okamžite vymazané príznaky, ktoré nespĺňali všetky z uvedených podmienok. Na výstupe boli nakoniec označené reálne výskytu nájdených K-komplexov. Porovnanie nami navrhnutej detekcie oproti expertovi č.1 v prvom testovanom signále databázy je zobrazené na obrázku 3.22 spolu s jeho 70 s úsekom.



Obr. 3.22: Ukážka nájdených K-komplexov v porovnaní s expertom

3.5.4 Účinnosť realizovanej metódy

Funkčnosť ako aj účinnosť tejto metódy môžeme zhodnotiť ako druhú najlepšiu z doposiaľ naprogramovaných. V porovnaní s metódou navrhnutou a realizovanou v predchádzajúcej kapitole 3.4, musíme však skonštatovať, že má ešte mierne nedostatky.

Tab. 3.9: Množstvo nájdených K-komplexov v signáloch databázy

Názov	Expert 1	Expert 2	Auto. detektor	Navrhnutý detektor
Signál 1	34	19	22	48
Signál 2	45	8	37	37
Signál 3	12	3	14	10
Signál 4	78	14	63	93
Signál 5	39	20	40	69

V niektorých prípadoch našla táto detekcia viac vzorov, ktoré považovala za K-komplexy, čo je dokázateľné v tabuľke 3.9, kde je uvedený celkový počet detegovaných vzorov v piatich testovaných signáloch. Keď vynecháme kvantitatívne hodnotenie a zameriame sa na citlivosť tohto algoritmu, môžeme vidieť priaznivejšie hodnoty ako pri ostatných predchádzajúcich metódach. To posudzujeme na základe vypočítaných hodnôt senzitivity, ktoré dosiahli vždy viac ako 50 %. Pozitívna prediktívna hodnota sa opäť pohybuje vo väčšom rozmedzí a to od 10,75 % do 78,38 %.

Tab. 3.10: Prehľad štatistických hodnôt pre porovnanie s referenciami

	Názov	Signál 1	Signál 2	Signál 3	Signál 4	Signál 5
Detekcia	Počet	48	37	10	93	69
Expert 1	Počet	34	45	12	78	39
	Zhoda	24	29	6	52	37
	<i>Se</i>	70,59	64,44	50,00	66,67	94,87
	<i>PPV</i>	50,00	78,38	60,00	55,91	53,62
Expert 2	Počet	19	8	3	14	20
	Zhoda	11	4	2	10	18
	<i>Se</i>	57,89	50,00	66,67	71,43	90,00
	<i>PPV</i>	22,92	10,81	20,00	10,75	26,09
A. detektor	Počet	22	37	14	63	40
	Zhoda	13	26	7	38	32
	<i>Se</i>	59,09	70,27	50,00	60,32	80,00
	<i>PPV</i>	27,08	70,27	70,00	40,86	46,38

3.6 Štatistické porovnanie účinnosti algoritmov

Zhrnutie a porovnanie navrhnutých metód spočívalo najprv v kvantitatívnom porovnaní nájdených K-komplexov, ktorý sme pre jednotlivé signály zhodnotili v predchádzajúcich podkapitolách 3.1.4, 3.2.4, 3.3.4, 3.4.4 a 3.5.4. Skôr ako počet K-komplexov nás však zaujímali súhlasné hodnotenia medzi detektorom a referenciou. Preto sme museli výsledky získané od odborníkov previesť do vhodnej formy. Následne sme od každého tohto bodu hľadali v časovom rozmedzí 1 s maximum určujúce presnejšiu polohu K-komplexu. Získané hodnoty boli potom porovnávané s hodnotami nájdenými pomocou navrhnutého algoritmu. Pre lepší prehľad a následné štatistické vyhodnotenie sme vyznačili aj zhody, ktorých sa nám podarilo dosiahnuť v porovnaní s hodnotením experta.

Podľa kvantitatívnych hodnotení sme následne chceli štatisticky vyjadriť úspešnosť týchto metód. Aby sme mohli posúdiť, ktorá realizovaná metóda detegovala K-komplexy s najvyššou presnosťou, potrebovali sme vypočítať niektoré štatistické parametre. Tie však nepočítajú len s nájdenými a nenájdenými K-komplexmi oproti referenciám, ale tiež s reálne falošnými vzormi, ktorých hodnotu v takomto type signálov nikdy nepoznáme. Preto sme určili, že je možnosť, aby sa v každej sekunde nachádzal jeden K-komplex a s týmto tvrdením sme mohli ďalej dopočítať potrebné parametre.

Získané štatistické hodnoty nám umožnili vypočítať priemernú senzitivitu a priemernú pozitívnu prediktívnu hodnotu pre jednotlivé navrhnuté algoritmy, ktoré sú zhrnuté v tabuľke 3.11. Ich číselné hodnoty sú vo všetkých tabuľkách tejto práce vyjadrené v percentách.

Tab. 3.11: Priemerné hodnoty štatistických parametrov

Metóda s využitím	Priemerná Se	Priemerná PPV
Fuzzy hodnôt a FIR filtrácie	51,55	31,37
Fuzzy hodnôt a IIR filtrácie	58,61	39,20
TKEO	43,27	24,79
Vlnkovej transformácie	63,83	44,07
Dekompozície signálu	66,82	42,87

Podľa tejto tabuľky môžeme zhodnotiť, že najperspektívnejším algoritmom z nami navrhnutých je práve ten, ktorý sa zakladá na vlnkovej transformácii, popísaný v kapitole 3.4. Ten síce nedosiahol najvyššiu priemernú senzitivitu 63,83 %, ale jeho vypočítaná priemerná pozitívna prediktívna hodnota dosiahla až 44,07 %, čo bolo najviac spomedzi realizovaných metód.

Pri navrhovaní detektorov fyziologických alebo patologických vzorov by mali byť tieto hodnoty určite vyššie. To sa nám však nepodarilo dosiahnuť. Aj keď štatistické testy majú celkom priaznivé hodnoty u väčšiny testovaných signálov, nemôžeme určiť, či nami navrhnuté detektory fungujú dostatočne správne. Samotné výsledky, s ktorými sme výstupy algoritmu porovnávali, si nie sú dostatočne podobné. Jedná sa hlavne o podstatne odlišné hodnotenia oboch expertov a automatickej detekcie v počtoch nájdených K-komplexov.

Ďalšie hodnotenie navrhnutých metód spočívalo v ich porovnaní s článkami, z ktorých vychádzali. Najprv sme sa zamerali na článok [11], s ktorým boli porovnávané detekcie navrhnuté v kapitolách 3.1 a 3.2. Do tabuľky 3.12 sme zhrnuli priemerné hodnoty senzitivity, pre každú z nich v porovnaní s vizuálnym hodnotením experta č.1 a experta č.2. V tomto prípade je viditeľné, že sa dosiahnuté výsledky zásadne nelíšili a dosahovali vyšších hodnôt ako je 54,00 %.

Tab. 3.12: Priemerná senzitivita metód vychádzajúca z rovnakého článku [11]

Metóda detekcie využívajúca	Priemerná Se pre	
	Expert 1	Expert 2
Fuzzy hodnoty z článku [11]	61,72	60,94
Fuzzy hodnoty a FIR filtráciu	55,58	54,21
Fuzzy hodnoty a IIR filtráciu	58,71	65,98

V tabuľke 3.13 sme sústredili pozornosť na metódy, ktoré aspoň čiastočne vychádzali z článku [14]. Taktiež sme porovnávali dosiahnutú priemernú senzitivitu proti hodnoteniam od expertov. Ako prvé si môžeme všimnúť, že výsledky z článku dosahujú veľmi vysokých hodnôt oproti nami realizovaným metódam. Tento fakt je spôsobený testovaním aj porovnávaním detektoru z článku a navrhnutých detektorov na dvoch rozdielnych databázach, čo môže pri vyhodnocovaní spánkových signálov značne skresľovať výsledky.

Tab. 3.13: Priemerná senzitivita metód vychádzajúca z rovnakého článku [14]

Metóda detekcie využívajúca	Priemerná Se pre	
	Expert 1	Expert 2
TKEO a vlnkovú transformáciu z článku [14]	80,00	89,00
TKEO	44,70	48,26
Vlnkovú transformáciu	65,21	67,20
Dekompozíciu signálu pomocou vlnkovej transformácie	69,31	67,20

Konečné porovnávanie bolo prevedené voči výsledkom z článku [11], ktorý pracoval s identickou databázou signálov. To nám umožnilo objektívnejšie hodnotenie funkčnosti detektorov vyjadrené v tabuľke 3.14, opäť pomocou priemernej senzitivity.

Tab. 3.14: Porovnanie metódy z článku [11] proti nami realizovaným metódam

Metóda detekcie využívajúca	Priemerná Se
Fuzzy hodnoty z článku [11] - referencia	61,33
Fuzzy hodnoty a FIR filtráciu	44,78
Fuzzy hodnoty a IIR filtráciu	51,15
TKEO	36,84
Vlnkovú transformáciu	59,08
Dekompozíciu signálu pomocou vlnkovej transformácie	63,94

Z výsledných hodnôt vyplýva, že najslabšie výsledky v tejto oblasti dosiahla metóda založená na TKEO popísaná v kapitole 3.3. Nepodarilo sa ju optimálne nastaviť, čo sa odrazilo tiež na jej neschopnosti akejkoľvek detekcie v signále č.3. Naopak najlepšia účinnosť v porovnaní s detektorom v článku bola dosiahnutá metódou založenou na dekompozícii signálu pomocou vlnkovej transformácie rozoberanou v kapitole 3.5, ktorá dosiahla priemernú senzitivitu 63,94 %. V oblasti hodnotenia pomocou priemernej senzitivity ju teda považujeme za najlepší z uvedených spôsobov detekcie K-komplexov.

4 Záver

V tejto bakalárskej práci sme sa venovali problematike spojenej so zaznamenávaním a vyhodnocovaním spánkových EEG signálov. V prvej časti boli vysvetlené teoretické základy dôležité, nie len pre pochopenie samotnej práce, ale aj pre ďalšie špecifické metódy detekcie K-komplexov.

Pokračovali sme časťou práce, ktorá sa sústredila skôr na vysvetlenie pojmov, rytmov a samotných vzorov objavujúcich sa na spánkových záznamoch. Spolu s tým však súviselo aj spracovávanie spánkových signálov, ktoré je aj podrobne zhrnuté.

Praktická časť práce bola zameraná na samotnú detekciu K-komplexov. Od zhrnutia používaných metód po návrh a realizáciu algoritmov. Prvá navrhnutá metóda bola inšpirovaná už existujúcou poloautomatickou detekciou na základe fuzzy prahových hodnôt a FIR predspracovaní. Táto detekcia bola následne testovaná na poskytnutej databáze, kde dosahovala hodnoty senzitivity v rozmedzí od 42,11 % až do 87,50 %. Na druhej strane sa však pozitívna prediktívna hodnota pohybovala v okolí nižších hodnôt a to práve od 8,26 % do 62,50 %. Tieto výsledky boli pravdepodobne zapríčinené nevhodnou filtráciou a následnou nesprávnou voľbou pravdepodobnostných hodnôt výskytu.

Keďže predchádzajúca metóda mala veľmi perspektívny základ, tak sme sa rozhodli urobiť pár úprav. Navrhli sme teda v poradí druhú metódu detekcie pomocou fuzzy prahových hodnôt. Táto sa však líšila nie len v type predspracovania, ale aj v type vyhľadávaných príznakov a tiež v ich množstve. Po testovaní sa ukázalo, že jej dosahovaná senzitivita sa pohybovala v rozmedzí od 21,43 % až do 87,50 %. V tomto prípade bolo však zaznamenané o niečo väčšie rozpätie pozitívnej prediktívnej hodnoty pohybujúce sa medzi 9,80 % a 81,08 %.

Následujúci algoritmus vychádzal z výpočtu energie signálu pomocou TKEO. V tomto prípade sme ďalej zvolili techniku okamžitého odstraňovania príznakov ak nezodpovedali aspoň jednej podmienke, ktoré sme si stanovili. Čo nám umožnilo nájsť menej falošne pozitívnych K-komplexov. Po procese testovania, sme vypočítali hodnoty senzitivity, ktoré dosahovali hodnôt od 35,00 % až do 71,43 %. Pozitívna prediktívna hodnota bola v tomto prípade stanovená v rozmedzí 8,62 % a 69,70 %.

Ďalší navrhovaný detektor pre K-komplexy bol zameraný na využitie vlnkovej transformácie pre vhodnejšiu extrakciu potrebných príznakov. Opäť bol tento detektor navrhnutý a testovaný na poskytnutej databáze. Tu sa nám podarilo dosiahnuť hodnoty senzitivity od 50,00 % až do 90,00 %. Dopočítaná pozitívna prediktívna hodnota sa pohybovala od 11,63 % do 84,85 %.

Posledná bola navrhnutá metóda s využitím dekompozície pomocou vlnkovej transformácie. Od tejto metódy sme očakávali, že bude optimálnejšia a správnejšia ako tá, čo používa aj spätnú vlnkovú transformáciu. Po testovaní sa ukázalo, že

sa jej výsledkom skutočne približuje. V tomto prípade sa senzitivita pohybovala od 50,00 % až do 94,87 %. Pozitívna prediktívna hodnota však dosahovala menšie hodnoty a to v intervale od 10,75 % do 78,38 %.

Ako sme už spomenuli, všetky metódy detekcie boli testované na poskytnutej databáze voči priloženým referenčným hodnoteniam. Mimo samotného vyhodnotenia štatistických parametrov môžeme skonštatovať, že v dvoch metódach neboli v signále č.3 detegované žiadne K-komplexy. Táto skutočnosť nastala pravdepodobne kvôli veľkej odlišnosti tohto signálu od ostatných, čo sa týka najmä amplitúdového rozsahu. Preto stanovené prahové hodnoty, ktoré v ostatných signáloch databázy obmedzovali detekciu falošne pozitívnych výsledkov, nedovolili nájsť v tomto prípade ani jeden K-komplex.

Za najlepšie navrhnutú a realizovanú metódu detekcie K-komplexov v tejto práci teda považujeme algoritmus, ktorý využíval vlnkovú transformáciu so všetkými jej krokmi: dekompozíciou, prahovaním a rekompozíciou. Usudzujeme tak najmä z dopočítanej priemernej senzitivity (63,83 %) a pozitívnej prediktívnej hodnoty (44,07 %).

Na záver môžeme konštatovať, že pre praktické použitie týchto algoritmov, by bolo nutné sa zamerať na ich ďalšiu optimalizáciu. Tá by mala byť orientovaná na výber vhodnejších hľadaných príznakov, čo sa týka typu aj množstva. V tejto práci sme odskúšali niekoľko príznakov, preto by bolo potrebné sa zamerať na ich správnu kombináciu pri budúcich detekciách. Tiež by bolo vhodné odskúšať viac signálov pre nastavenie optimálnych prahových hodnôt, ktoré by boli vyhovujúce pre väčšinu z nich.

Všetky zistené skutočnosti však vyplývajú z toho, že spánkové EEG signály sú veľmi variabilné u každého človeka, preto sa nám pri štatistickom hodnotení naprogramovaných detektorov nepodarilo dosiahnuť väčších hodnôt senzitivity a lepšej schopnosti pozitívnej predikcie.

Literatúra

- [1] CHOKROVERTY, Sudhansu a Robert J. THOMAS. *Atlas of Sleep Medicine* 2nd ed. New York: Saunders, 2014. ISBN 978-1-4557-1267-0.
- [2] American Association of Sleep Technologists. *Standard Polysomnography* [online]. [cit. 11. 11. 2018]. Dostupné z: <https://www.aastweb.org/hubfs/Technical%20Guidelines/Updated%206.14.2017/StandardPSG.pdf?fbclid=IwAR2jExv8gtvWY5GNgyV03c6UjUGQLzTcDMBQ5cXZLx22lkjblkWZzSWIIFQ>
- [3] Polysomnography: Sleep diagnose. AYSTESIS CLINIC [online]. San José, Costa Rica: CLINICA AYSTESIS, 2017 [cit. 2019-04-01]. Dostupné z: <https://aystesis.com/polysomnography/>
- [4] AVIDAN, Alon Y. a Teri J. BARKOUKIS. *Review of Sleep Medicine*. 3rd ed. United States of America: Philadelphia, 2007. ISBN 978-1-4557-0319-7.
- [5] SANEI, Saeid. *Adaptive processing of brain signals*. 1. UK: Wiley, 2013. ISBN 978-0-470-68613-3.
- [6] KAMEL, Nidal a Aamir Saeed MALIK. *EEG/ERP Analysis: Methods and applications*. Boca Raton: CRC Press, 2015. ISBN 978-1-4822-2471-9.
- [7] *Biomedical signal processing and control*. Oxford, UK: Elsevier, 2006. ISSN 1746-8094.
- [8] M. RANGAYYAN, Rangaraj. *Biomedical Signal Analysis*. 2nd ed. [online]. Hoboken, NJ: USA: John Wiley, 2015. ISBN 9781119068129.
- [9] BERRY, Richard B. *Fundamentals of sleep medicine* USA: Elsevier Saunders, 2012. ISBN 978-1-4377-0326-9.
- [10] CHOKROVERTY, Sudhansu. *Sleep Disorders Medicine: Basic Science, Technical Considerations, and Clinical Aspects*. 3rd ed. New York: Saunders, 2009. ISBN 978-0-7506-7584-0.
- [11] DEVUYST, S, T DUTOIT, P STENUIT a M KERKHOF, 2010. *Automatic K-complexes detection in sleep EEG recordings using likelihood thresholds*. In: 2010 Annual International Conference of the IEEE Engineering in Medicine and Biology. IEEE, 2010, s. 4658-4661
- [12] JAN, Jiří. *Číslíková filtrace, analýza a restaurace signálů*. 2. uprav. vydání Brno: Vysoké učení technické v Brně, 2002. ISBN 80-214-1558-4.

- [13] KROHNE, Laerke K., Rie B. HANSEN, Julie A. E. CHRISTENSEN, Helge B. D. SORENSEN a Poul JENNUM, 2014. *Detection of K-complexes based on the wavelet transform*. In: 2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society. IEEE, 2014, s. 5450-5453
- [14] ERDAMAR, Aykut, Fazil DUMAN a Sinan YETKIN. *A wavelet and teager energy operator based method for automatic detection of K-Complex in sleep EEG. Expert Systems with Applications*. [online] 2012, 39(1), 1284-1290 [cit. 2019-03-20]. DOI: 10.1016/j.eswa.2011.07.138. ISSN 09574174. Dostupné z: <https://www.sciencedirect.com/science/article/pii/S0957417411011110>

Zoznam symbolov, veličín a skratiek

Ag/AgCl	argentchloridový
EEG	elektroencefalografia
EKG	elektrokardiografia
EMG	elektromyografia
EOG	elektrookulografia
FIR	konečná impulzná charakteristika
FN	False Negative, falošne negatívny
FP	False Positive, falošne pozitívny
IIR	nekonečná impulzná charakteristika
NREM	spánok bez rýchleho pohybu očí
PPV	pozitívna prediktívna hodnota
PSG	polysomnografia
REM	spánok s rýchlym pohybom očí
Se	senzitivita
Sp	špecifita
TKEO	Teager-Kaiser energetický operátor
TN	True Negative, skutočne negatívny
TP	True Positive, skutočne pozitívny

Zoznam príloh

A Obsah priloženého CD

60

A Obsah priloženého CD

1. elektronickú verziu tejto práce vo formáte .pdf
2. databázu signálov spolu s referenčnými hodnoteniami od expertov
3. skripty s hlavnými algoritmami:
 - BP_FIR_Fuzzy.m
 - BP_IIR_Fuzzy.m
 - BP_TeagerKaiser.m
 - BP_vlnkova_transformacia.m
 - BP_DWT.m
4. skripty s funkciami k prvým dvom z hlavných algoritmov:
 - find_start.m
 - find_end.m
 - find_mid1.m
 - find_mid2.m
 - realKC.m
 - IIR_realKC.m
5. návod pre spustenie a testovanie algoritmov